



TUGAS AKHIR - SS141501

**SEGMENTASI CITRA OTAK *MAGNETIC RESONANCE IMAGING* (MRI) MENGGUNAKAN *GAUSSIAN MIXTURE MODEL* (GMM) DENGAN PENDEKATAN *EXPECTATION MAXIMIZATION* (EM) DALAM PEMBENTUKAN CITRA 3 DIMENSI**

**SITI AZIZAH NURUL SOLICHAH**  
**NRP 062116 4500 0008**

Dosen Pembimbing  
**Prof. Drs. Nur Iriawan, M.Ikom, Ph. D**

**PROGRAM STUDI SARJANA**  
**DEPARTEMEN STATISTIKA**  
**FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA**  
**INSTITUT TEKNOLOGI SEPULUH NOPEMBER**  
**SURABAYA 2018**



**TUGAS AKHIR - SS141501**

**SEGMENTASI CITRA OTAK *MAGNETIC RESONANCE IMAGING* (MRI) MENGGUNAKAN *GAUSSIAN MIXTURE MODEL* (GMM) DENGAN PENDEKATAN *EXPECTATION MAXIMIZATION* (EM) DALAM PEMBENTUKAN CITRA 3 DIMENSI**

**SITI AZIZAH NURUL SOLICHAH  
NRP 062116 4500 0008**

**Dosen Pembimbing  
Prof. Drs. Nur Iriawan, M.Ikom, Ph. D**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**



**FINAL PROJECT - SS141501**

**GAUSSIAN MIXTURE MODEL WITH  
EXPECTATION MAXIMIZATION FOR MRI IMAGE  
SEGMENTATION TO BUILD 3 DIMENSION  
IMAGE ON BRAIN TUMOR AREA**

**SITI AZIZAH NURUL SOLICHAH  
SN 062116 4500 0008**

**Supervisors**

**Prof. Drs. Nur Iriawan, M.Ikom, Ph. D**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**

## LEMBAR PENGESAHAN

### **SEGMENTASI CITRA OTAK *MAGNETIC RESONANCE IMAGING* MENGGUNAKAN *GAUSSIAN MIXTURE MODEL* DENGAN PENDEKATAN *EXPECTATION MAXIMIZATION* DALAM PEMBENTUKAN CITRA 3 DIMENSI**

#### **TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
Pada

Program Studi Sarjana Departemen Statistika  
Fakultas Matematika, Komputasi, dan Sains Data  
Institut Teknologi Sepuluh Nopember

Oleh :

**Siti Azizah Nurul Solichah**  
NRP. 062116 4500 0008

Disetujui oleh Pembimbing:

**Prof. Drs. Nur Iriawan, M.Ikom, Ph.D**  
NIP. 19621015 198803 1 002

(  )



Mengetahui,  
Kepala Departemen

**Dr. Suhartono**  
NIP. 19710929 199512 1 001

SURABAYA, JULI 2018

# **SEGMENTASI CITRA OTAK *MAGNETIC RESONANCE IMAGING* (MRI) MENGGUNAKAN *GAUSSIAN MIXTURE MODEL* (GMM) DENGAN PENDEKATAN *EXPECTATION MAXIMIZATION* (EM) UNTUK MEMBENTUK CITRA 3 DIMENSI**

**Nama** : Siti Azizah Nurul Solichah  
**NRP** : 06211645000008  
**Departemen** : Statistika  
**Dosen Pembimbing** : Prof. Drs. Nur Iriawan, M.Ikom, Ph. D

## **Abstrak**

*Tumor otak merupakan massa dari sel yang tidak diperlukan yang tumbuh di dalam saluran syaraf pusat. Tumor otak memberikan permasalahan klinis yang agak berbeda dengan tumor lain karena efek yang ditimbulkannya dan keterbatasan terapi yang dapat dilakukan. Salah satu peralatan medis yang digunakan untuk mendeteksi tumor otak yaitu Magnetic Resonance Imaging atau MRI. Untuk meningkatkan kualitas dari citra MRI tumor otak diperlukan suatu pendekatan segmentasi citra. Segmentasi objek di dalam citra bertujuan memisahkan region objek dengan wilayah latar belakang sehingga didapatkan hasil yang lebih mudah untuk dilakukan analisis selanjutnya. Banyak metode yang dikembangkan untuk segmentasi citra dalam ilmu statistika komputasi, salah satunya Model Based Clustering. Gaussian mixture model (GMM) merupakan model mixture yang paling sering digunakan dalam model based clustering khususnya pada segmentasi citra. GMM sering digunakan dalam klasifikasi hasil magnetic imaging resonance (MRI), positron emission tomography (PET), computed tomography (CT), dan hasil scan dalam dunia kedokteran lainnya. Kluster yang dapat memisahkan area tumor dengan area otak adalah 6 kluster sehingga model 3 dimensi dapat dibentuk untuk memperjelas penggambaran otak.*

**Kata Kunci:** *tumor otak; Expectation Maximization; Gausssian mixture model; segmentasi citra; MRI.*

*(Halaman ini sengaja dikosongkan)*

# GAUSSIAN MIXTURE MODEL WITH EXPECTATION MAXIMIZATION FOR MRI IMAGE SEGMENTATION TO BUILD 3 DIMENSION IMAGE ON BRAIN TUMOR AREA

**Student Name** : Siti Azizah Nurul Solichah  
**Student Number** : 06211645000008  
**Department** : Statistics  
**Supervisor** : Prof. Drs. Nur Iriawan, M.Ikom, Ph. D

## Abstract

*Brain tumor is such an unnecessary mass that growing inside central spine canal. It gives different clinical problem compared with other tumor cases because of its effects and limited therapy that applied. Primary brain tumor generally diagnosed in children and older adults. RSUD Dr. Soetomo Surabaya recorded the increasing of brain tumor cases and it occurs most frequently in women. One of imaging methods for diagnosis is Magnetic Resonance Imaging (MRI) that based on computer simulation of human body with approach of tomography. Imaging technique of MRI nearly complex because the image result based on the amount and optimal selecting of parameters. Therefore, image segmentation to enhance imaging result quality of MRI is needed. Object segmentation in an image is to separate object region and background region for easier further analytic. Gaussian mixture model frequently used for model based clustering especially image segmentation. GMM commonly used in image result clustering for Magnetic Resonance Imaging (MRI), positron emission tomography (PET), computed tomography (CT), and any others clinical scan. 6 clusters can divide ROI and Non-ROI so modeling on 3 dimension could be easier. 3 dimension modeling did on each slice (axial, coronal, sagittal).*

**Keywords:** *brain tumor; Expectation Maximization; Gausssian mixture model; image segmentation; MRI.*

*(Halaman ini sengaja dikosongkan)*



## KATA PENGANTAR

Puji syukur kepada Allah SWT karena berkat rahmat, karunia, taufik, dan hidayah-Nya penulis dapat menyelesaikan Tugas Akhir yang berjudul “**Segmentasi Citra Otak *Magnetic Resonance Imaging* (MRI) Menggunakan *Gaussian Mixture Model* (GMM) dengan Pendekatan *Expectation Maximization* (EM) dalam Pembentukan Citra 3 Dimensi**”.

Tugas Akhir ini dapat terselesaikan dengan baik karena bantuan, dukungan, dan peran serta dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan terima kasih kepada.

1. Bapak Prof. Drs. Nur Iriawan, M.Ikom, Ph.D selaku dosen pembimbing yang telah membimbing dan mengarahkan dengan sabar untuk dapat menyelesaikan Tugas Akhir ini.
2. Ibu Pratnya Paramitha Oktaviana, S.Si, M.Si dan Ibu Dr. Dra. Kartika Fithriasari, M.Si selaku dosen penguji yang telah memberikan saran-saran yang membangun untuk kesempurnaan Tugas Akhir ini.
3. Ibu Dr. Dra. Ismaini Zain, M.Si selaku dosen wali yang telah memberikan nasehat, motivasi, serta bimbingan kepada penulis selama penulis menempuh pendidikan.
4. Bapak Dr. Suhartono selaku Kepala Departemen Statistika FMIPA-ITS.
5. Bapak Dr. Sutikno, M.Si selaku Ketua Program Studi Sarjana Departemen Statistika FMIPA ITS.
6. Ibu Anindya Apriliyanti Pravitasari, S.Si., M.Si., atas bantuan, nasihat, kritik, dan saran, yang diberikan selama penyelesaian Tugas Akhir ini beserta Tim TA Segmentasi Citra yang terdiri dari Miftakhul Ilmi Dinul Islamiyah, Miftakhul Ardi Ikhwanus Safa, dan Sandra Firda Qonita yang sudah membantu dan bekerja sama selama ini.
7. dr. Widiana Ferriastuti, Sp. Rad (K) atas bantuan, saran, dan waktu yang diberikan kepada penulis dalam pemberian rekomendasi untuk Tugas Akhir ini.

8. Seluruh dosen dan *civitas academica* Departemen Statistika ITS yang telah memberikan ilmu yang berharga serta telah membantu kelancaran pelaksanaan perkuliahan.
9. Ibu dan Bapak yang sangat penulis cintai dan hormati, Heny Rachmawati dan Kuntarto Harsoyo, tanpa doa dan seluruh dukungan mereka penulis bukanlah apa-apa.
10. Sahabat tercinta sejak di bangku sekolah menengah, Ayu Wanda Saraswati, Sekar Fathiya Azni, Novi Ajeng Salehah, Vina Auditia, Jelita Budiarti, Sifana Zana Masyitha, dan Denisa Dwi Rahmayani yang memberikan semangat, doa, dan hiburan yang tak henti-hentinya.
11. Sahabat-sahabat selama kuliah, Putri Ayu Sekar Karimah, Yongky Choirul Anam, Nym Cista Striratna Dewi, Rakhmah Wahyu Mayasari, dan Fransiska Kristin Damayanti terutama Genk LOL's Kombong tercinta yang terdiri dari Mbak Linda Chrestina Fadillah R., Zuyyin Inesa Pratiwi, Raras Anasi, Inung Anggun Saputri, Rima Kusumawati, Camelia Nanda Solicha, Mbak Jauhara Rana Budiani, dan Mas Novan Asmaranda yang selalu memberi semangat serta hiburan selama masa kuliah dan menemani di saat suka maupun duka.
12. Semua mahasiswa Lintas Jalur Statistika ITS angkatan 2016 terutama Teman Selusin yang telah menemani, belajar bersama, dan tertawa bersama.

Penulis berharap semoga laporan Tugas Akhir ini bermanfaat dan menambah wawasan bagi pembaca. Kritik dan saran sangat diperlukan untuk perbaikan di masa yang akan datang.

Surabaya, Juli 2018

**Penulis**

## DAFTAR ISI

<b>HALAMAN JUDUL</b> .....	i
<b>LEMBAR PENGESAHAN</b> .....	iii
<b>ABSTRAK</b> .....	v
<b>ABSTRACT</b> .....	vii
<b>KATA PENGANTAR</b> .....	ix
<b>DAFTAR ISI</b> .....	xi
<b>DAFTAR TABEL</b> .....	xiii
<b>DAFTAR GAMBAR</b> .....	xv
<b>DAFTAR LAMPIRAN</b> .....	xvii
<b>BAB I PENDAHULUAN</b>	
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	5
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	6
1.5 Batasan Masalah.....	6
<b>BAB II TINJAUAN PUSTAKA</b>	
2.1 Tumor Otak .....	7
2.2 <i>Magnetic Resonance Imaging (MRI)</i> .....	8
2.3 Segmentasi Citra Digital.....	9
2.4 Histogram Citra .....	11
2.5 <i>Gaussian Mixture Model</i> .....	12
2.6 Algoritma EM ( <i>Expectation Maximization</i> ) pada <i>Gaussian Mixture Model</i> .....	15
2.7 <i>Silhouette Coefficient</i> .....	18
<b>BAB III METODOLOGI PENELITIAN</b>	
3.1 Sumber Data .....	19
3.2 Variabel Penelitian .....	19
3.3 Langkah Analisis .....	20
3.4 Diagram Alir.....	21
<b>BAB IV ANALISIS DAN PEMBAHASAN</b>	
4.1 Karakteristik Hasil Citra MRI .....	23

4.2 Hasil <i>Clustering</i> Hasil Citra MRI Menggunakan <i>Gaus-sian Mixture Model</i> dengan Pendekatan <i>Expectation Maximization</i> (EM-GMM) .....	25
4.2.1 Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Axial</i> Menggunakan EM-GMM .....	31
4.2.2 Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Coronal</i> Menggunakan EM-GMM .....	35
4.2.3 Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Sagittal</i> Menggunakan EM-GMM .....	33
4.3 Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI .....	41
4.3.1 Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Axial</i> .....	
4.3.2 Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Coronal</i> .....	43
4.3.3 Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Sagittal</i> .....	45
<b>BAB V KESIMPULAN DAN SARAN</b>	
5.1 Kesimpulan .....	49
5.2 Saran .....	49
<b>DAFTAR PUSTAKA</b> .....	51
<b>LAMPIRAN</b> .....	55
<b>BIODATA PENULIS</b> .....	65

## DAFTAR TABEL

<b>Tabel 3.1</b>	Variabel Penelitian .....	19
<b>Tabel 2.2</b>	Struktur Data.....	19
<b>Tabel 4.1</b>	Parameter $\mu$ dari Citra <i>Slice Axial</i> .....	25
<b>Tabel 4.2</b>	Parameter $p$ dari Citra <i>Slice Axial</i> .....	26
<b>Tabel 4.3</b>	Parameter $\sigma^2$ dari Citra <i>Slice Axial</i> .....	27
<b>Tabel 4.4</b>	Parameter $\mu$ dari Citra <i>Slice Coronal</i> .....	31
<b>Tabel 4.5</b>	Parameter $p$ dari Citra <i>Slice Coronal</i> .....	31
<b>Tabel 4.6</b>	Parameter $\sigma^2$ dari Citra <i>Slice Coronal</i> .....	32
<b>Tabel 4.7</b>	Parameter $\mu$ dari Citra <i>Slice Sagittal</i> .....	36
<b>Tabel 4.8</b>	Parameter $p$ dari Citra <i>Slice Sagittal</i> .....	36
<b>Tabel 4.9</b>	Parameter $\sigma^2$ dari Citra <i>Slice Sagittal</i> .....	37

*(Halaman ini sengaja dikosongkan)*

## DAFTAR GAMBAR

<b>Gambar 2.1</b>	Bidang <i>Axial</i> , <i>Sagittal</i> , dan <i>Coronal</i> .....	9
<b>Gambar 2.2</b>	Skema Warna RGB dalam Kubus .....	10
<b>Gambar 2.3</b>	Histogram Citra .....	12
<b>Gambar 3.1</b>	Diagram Alir .....	21
<b>Gambar 4.1</b>	<i>Histogram Citra Slice Axial ke-19</i> .....	23
<b>Gambar 4.2</b>	<i>Histogram Citra Slice Coronal ke-10</i> .....	24
<b>Gambar 4.3</b>	<i>Histogram Citra Slice Sagittal ke-16</i> .....	24
<b>Gambar 4.4</b>	Histogram 6 Kluster Citra <i>Slice Axial</i> ke-19 .....	28
<b>Gambar 4.5</b>	Hasil Citra <i>Slice Axial</i> ke-19 (a) Gambar Asli (b) Hasil <i>Clustering</i> .....	29
<b>Gambar 4.6</b>	<i>NROI dan ROI dari Citra Slice Axial ke-19</i> .....	29
<b>Gambar 4.7</b>	Perbandingan Nilai <i>Silhouette Index</i> Klaster 5 hingga 8 <i>Slice Axial</i> .....	30
<b>Gambar 4.8</b>	<i>Histogram 6 Kluster Citra Slice Coronal ke-10</i> .....	33
<b>Gambar 4.9</b>	Hasil Citra <i>Slice Coronal</i> ke-10 (a) Gambar Asli (b) Hasil <i>Clustering</i> .....	34
<b>Gambar 4.10</b>	<i>NROI dan ROI dari Citra Slice Coronal ke-10</i> .....	34
<b>Gambar 4.11</b>	Perbandingan Nilai <i>Silhouette Index</i> Klaster 5 hingga 8 <i>Slice Coronal</i> .....	35
<b>Gambar 4.12</b>	<i>Histogram 6 Kluster Citra Slice Sagittal ke-16</i> .....	38
<b>Gambar 4.13</b>	Hasil Citra <i>Slice Sagittal</i> ke-16 (a) Gambar Asli (b) Hasil <i>Clustering</i> .....	39
<b>Gambar 4.14</b>	<i>NROI dan ROI dari Citra Slice Sagittal ke-16</i> .....	39
<b>Gambar 4.15</b>	Perbandingan Nilai <i>Silhouette Index</i> Klaster 3 hingga 8 <i>Slice Sagittal</i> .....	40
<b>Gambar 4.16</b>	Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Axial</i> .....	41
<b>Gambar 4.17</b>	Letak Tumor dalam Model 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Axial</i> .....	43
<b>Gambar 4.18</b>	Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Coronal</i> .....	44
<b>Gambar 4.19</b>	Letak Tumor dalam Model 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Coronal</i> .....	45

<b>Gambar 4.20</b>	Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Sagittal</i> .....	46
<b>Gambar 4.21</b>	Pemodelan 3 Dimensi Hasil <i>Clustering</i> Hasil Citra MRI <i>Slice Sagittal</i> .....	47



## DAFTAR LAMPIRAN

<b>Lampiran 1</b>	<i>Syntax Clustering dengan Gaussian Mixture Model dengan Pendekatan Expectation Maximization .....</i>	55
<b>Lampiran 2</b>	Hasil <i>Clustering</i> Beberapa <i>Slice</i> dari Citra MRI yang Terdapat Area Tumor Otak yang Tampak ..	59
<b>Lampiran 3</b>	<i>Syntax</i> Mendapatkan Nilai <i>Silhouette Index</i> .....	63
<b>Lampiran 4</b>	Surat Pernyataan Data Sekunder .....	64

*(Halaman ini sengaja dikosongkan)*

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Otak merupakan organ vital yang sangat penting bagi manusia, di mana otak memiliki kemampuan untuk mengendalikan setiap aktivitas yang dilakukan oleh manusia baik dalam keadaan sadar maupun tidak sadar. Aktivitas yang dilakukan seperti menggerakkan tangan, kaki, mata, maupun merasakan keadaan yang ada di luar sistem tubuh manusia. Aktivitas kerja otak merupakan aktivitas kelistrikan yang sifatnya terus-menerus. Kondisi abnormal merupakan kondisi yang berhubungan dengan gangguan neurologis (fungsi kerja otak) (Kumbara, 2015). Salah satu penyakit yang menyerang otak adalah tumor otak.

Tumor otak merupakan massa dari sel yang tidak diperlukan yang tumbuh di dalam saluran syaraf pusat. Tumor otak dapat berupa tumor yang sifatnya primer ataupun yang merupakan metastasis dari tumor pada organ lainnya. Tumor otak primer tumbuh dan cenderung bertahan di otak sedangkan tumor otak metastatis dimulai sebagai kanker di bagian tubuh dan menyebar ke otak (American Brain Tumor Association, 2015). Tumor otak memberikan permasalahan klinis yang agak berbeda dengan tumor lain karena efek yang ditimbulkannya dan keterbatasan terapi yang dapat dilakukan. Tumor otak yang menimbulkan kerusakan pada jaringan otak secara langsung akan menyebabkan gangguan fungsional dari sistem saraf pusat, berupa gangguan motorik, sensorik, panca indera, bahkan kemampuan kognitif. Selain itu efek massa yang ditimbulkan tumor otak akan memberikan masalah serius mengingat tumor berada dalam rongga tengkorak yang pada orang dewasa merupakan suatu ruang tertutup dengan ukuran yang tetap (Wahjoepramono, 2006).

Tumor otak primer dapat terjadi pada semua orang dari segala usia, namun secara statistik lebih sering terjadi pada anak-anak dan orang tua. Dimana usia rata-rata saat diagnosis untuk semua tumor otak primer adalah 59 tahun. Sedangkan pada anak-anak tumor otak paling umum terjadi saat usia 0-14 tahun. Pada tahun 2017, di-

perkiraan terdapat 80.000 kasus baru tumor otak primer di Amerika Serikat yang mencakup 26.000 tumor otak ganas dan 53.000 tumor otak jinak dengan 4.800 diantaranya adalah anak-anak dan remaja yang berusaha 0-19 tahun (American Brain Tumor Association, 2015). Di Indonesia kasus tumor otak kasus kejadian tumor dan kanker otak sudah mencapai angka 4.900 kasus pada tahun 2012 (Wijaya R. , 2017).

RSUD Dr. Soetomo merupakan salah satu rujukan pasien tumor otak. Rumah Sakit Umum Daerah (RSUD) Dr. Soetomo mencatat bahwa jumlah kasus penyakit tumor otak setiap tahunnya meningkat dan sebagian besar penderitanya adalah perempuan. Meski bukan yang tertinggi, kasus tumor otak masih menjadi salah satu momok bagi sebagian masyarakat setelah kanker serviks, payudara, dan paru-paru. Hingga 2015, 1 dari 888.793 orang di Indonesia beresiko terkena tumor otak sedangkan di Surabaya rasionya adalah 1 dari 154.186 orang. Meskipun rasionya masih cenderung lebih kecil dibandingkan penyakit lainnya, namun bahaya tumor otak tetap perlu diwaspadai (Berita Jatim, 2015).

Salah satu peralatan medis yang digunakan untuk mendeteksi tumor otak yaitu *Magnetic Resonance Imaging* atau MRI. MRI merupakan sarana penunjang diagnostik yang sangat penting yang merupakan bagian dari modalitas *imaging* yang didasarkan pada komputer yang memeragakan potongan-potongan tubuh secara tomografi. Berbeda dengan CT yang memerlukan radiasi ionisasi, MRI didasarkan pada interaksi antara gelombang radio dan inti atom hidrogen dalam tubuh oleh adanya medan magnet (Rofiky, Rahardjo, & Soeharmanto, 2017). Teknik penggambaran MRI relatif kompleks karena gambaran yang dihasilkan tergantung pada banyak parameter. Bila pemilihan parameter tersebut tepat, kualitas gambar MRI dapat memberikan gambaran detail tubuh manusia dengan perbedaan yang kontras, sehingga anatomi dan patologi jaringan tubuh dapat dievaluasi secara teliti. (Noyosiswoyo & Suswati, 2004). Tetapi jika parameter tersebut kurang tepat dimungkinkan hasil keluaran MRI tidak memberikan gambar yang detail, sehingga proses diagnosis mengenai posisi tumor otak memerlukan pertim-

bagian lainnya. Salah satu parameter yang memengaruhi waktu adalah *Number of Diffusion Gradient Direction* (NDGD). RSUD Dr. Soetomo melakukan prosedur MRI berdurasi 8 menit dengan NDGD 25. Waktu pemeriksaan yang lama akan berpotensi menyebabkan *noise* karena pergerakan pasien (Rofiky, Rahardjo, & Soeharmanto, 2017).

MRI yang sering digunakan adalah yang memiliki kekuatan 1,5 tesla, 3 tesla, dan 7 tesla. Hasil MRI dengan kekuatan 1,5 tesla dan 3 tesla menghasilkan perbandingan yang tidak terlalu berbeda. Untuk keperluan diagnosa, MRI berkekuatan 1,5 tesla dan 3 tesla lebih dapat diandalkan untuk memberikan diagnosa yang lebih baik karena memiliki kualitas citra yang lebih tinggi. MRI dengan kekuatan 7 tesla memang menghasilkan resolusi yang lebih besar namun malah menyulitkan proses diagnose pasien. Sehingga dapat dikatakan MRI dengan kekuatan 7 tesla tidak lebih baik jika dibandingkan dengan MRI berkekuatan 1,5 tesla dan 3 tesla. (Laader, et al., 2017). RSUD Dr. Soetomo menggunakan MRI berkekuatan 1,5 tesla dan 3 tesla untuk prosedur *scan* pasien-pasiennya. Dari segi harga, prosedur *scan* MRI 1,5 tesla lebih terjangkau dan dapat ditanggung oleh BPJS dengan prosedur tertentu sehingga dapat membantu masyarakat golongan kurang mampu (Pasien BPJS, 2016). Dibandingkan dengan MRI 1,5 tesla, MRI 3 tesla memberikan resolusi yang spasial dan sangat bermanfaat untuk menghasilkan pencitraan pembuluh darah yang sebelumnya belum bisa terlihat (RS Premier Surabaya, 2017). Rumah sakit swasta telah banyak menggunakan MRI 3 tesla untuk pencitraan tidak hanya otak, namun juga pembuluh darah, jantung, hati, prostat, hingga *scan* seluruh tubuh dengan biaya yang lebih tinggi daripada prosedur MRI 1,5 tesla.

Oleh karena adanya permasalahan tentang kualitas citra, maka diperlukan suatu pendekatan untuk meningkatkan kualitas dari citra MRI tumor otak. Pendekatan komputasi untuk meningkatkan kualitas citra MRI tumor otak dapat dilakukan dengan menggunakan segmentasi citra. Segmentasi objek di dalam citra bertujuan memisahkan *region* objek dengan wilayah latar belakang sehingga didapatkan hasil yang lebih mudah untuk dilakukan analisis selan-

jutnya (Shapiro & Stockman, 2000). Secara digital suatu *grayscale* dapat direpresentasikan dalam bentuk *array* dua dimensi atau matriks. Tiap elemen pada *array* tersebut menunjukkan intensitas *grayscale* dari pada posisi koordinat yang bersesuaian. Apabila suatu image direpresentasikan dalam 8 bit, pada image terdapat  $2^8$  atau 256 level grayscale, biasanya bernilai 0-255 (Gonzales & Woods, 2008) Dimana 0 menunjukkan level intensitas yang paling gelap dan 255 menunjukkan intensitas paling terang. Banyak metode yang dikembangkan untuk segmentasi citra dalam ilmu statistika komputasi, salah satunya *clustering*. Salah satu metode yang dikembangkan untuk mengetahui pembagian *cluster*, perbandingan algoritma antar metode, dan penanganan *noise* dalam model heuristik adalah metode *Model Based Clustering*. *Model based clustering* merupakan metode yang berdasar pada model probabilitas dari data. *Model based clustering* mengasumsikan bahwa data dibangkitkan oleh campuran dari distribusi probabilitas dengan masing-masing komponen mewakili *cluster* berbeda sehingga objek didalam suatu *data set* dapat dikelompokkan menjadi kelompok data yang sebelumnya tidak terdefinisi. Beberapa *cluster* bisa memiliki distribusi yang sama atau berbeda-beda sehingga campuran dari distribusi probabilitas membentuk suatu *mixture model* (Shi, 2005). *Mixture model* adalah salah satu model khusus yang dapat digunakan untuk memodelkan data yang populasinya merupakan susunan dari beberapa sub populasi atau kelompok. Setiap sub populasi merupakan komponen penyusun dari model *mixture* serta mempunyai proporsi yang bervariasi untuk masing-masing komponennya (Gelman, Carlin, Stern, Dunson, Vehtari, & Rubin, 2014).

*Gaussian mixture model* (GMM) merupakan model *mixture* yang paling sering digunakan dalam *model based clustering* khususnya pada segmentasi citra. Hal ini karena GMM lebih sederhana dan parameter dapat diestimasi secara efisien dengan menggunakan *expectation maximization* (EM) *algorithm* (Ji, Huang, Xia, & Zheng, 2017). *Gaussian mixture model* (GMM) sering digunakan dalam klasifikasi hasil MRI (*magnetic imaging resonance*), PET (*positron emission tomography*), CT (*computed tomog-*

raphy), dan hasil *scan* dalam dunia kedokteran lainnya. Pengembangan GMM untuk segmentasi dalam kasus kesehatan dikarenakan GMM dapat diandalkan dalam pemodelan distribusi intensitas citra. Citra yang dihasilkan terlihat homogen pada target ataupun latar belakangnya sehingga menyulitkan diagnosa pasien. Sehingga dibutuhkan segmentasi citra dengan GMM agar hasil MRI dapat dibaca dengan mudah. Sejauh ini penelitian terhadap segmentasi citra khususnya pada data klinis sering menggunakan GMM daripada distribusi yang lain. (Aristophanous, Penney, Martel, & Pelizzari, 2007).

Penelitian ini diharapkan dapat menghasilkan suatu gambaran dengan model 3 dimensi sehingga dapat memperjelas visual tumor otak pasien. Gambaran yang dihasilkan dapat digunakan untuk membantu tenaga medis dalam mengetahui letak pasti tumor otak sehingga memudahkan proses diagnosa agar penanganan pasien tumor otak dapat lebih efisien dan efektif.

## 1.2 Rumusan Masalah

Seperti yang sudah dijelaskan dalam latar belakang, penelitian ini digunakan untuk menyelesaikan permasalahan hasil segmentasi citra MRI tumor otak menggunakan *Gaussian Mixture Model* dengan pendekatan *Expectation Maximization*. Penelitian sebelumnya oleh Sianipar (2017) hanya menghasilkan segmentasi citra namun dalam penelitian ini menggabungkan hasil citra MRI untuk membentuk citra 3 dimensi.

## 1.3 Tujuan Penelitian

Tujuan yang didapatkan ketika melakukan penelitian ini adalah sebagai berikut

1. Mendapatkan segmentasi citra MRI tumor otak menggunakan *Gaussian Mixture Model* dengan pendekatan *Expectation Maximization*
2. Membentuk citra 3 dimensi untuk memperjelas letak tumor otak yang sebenarnya

#### **1.4 Manfaat Penelitian**

Manfaat yang diharapkan dari penelitian ini adalah terbentuknya citra 3 dimensi sehingga mempermudah pendeteksian letak tumor untuk membantu paramedis di rumah sakit dalam diagnosa tumor otak.

#### **1.5 Batasan Masalah**

Terdapat beberapa batasan masalah yang digunakan yaitu:

1. Data rekam medis yang digunakan adalah citra MRI tumor otak berkekuatan 1,5 tesla
2. Segmentasi citra dilakukan pada semua *sequence* dalam satu hasil citra MRI



## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Tumor Otak**

Tumor otak merupakan massa dari sel yang tidak diperlukan yang tumbuh di dalam saluran syaraf pusat. Tumor otak dapat berupa tumor yang sifatnya primer ataupun yang merupakan metastasis dari tumor pada organ lainnya. Tumor otak primer tumbuh dan cenderung bertahan di otak sedangkan tumor otak metastatis dimulai sebagai kanker di bagian tubuh dan menyebar ke otak (American Brain Tumor Association, 2015). Tumor otak memberikan permasalahan klinis yang agak berbeda dengan tumor lain karena efek yang ditimbulkannya dan keterbatasan terapi yang dapat dilakukan. Tumor otak yang menimbulkan kerusakan pada jaringan otak secara langsung akan menyebabkan gangguan fungsional dari sistem saraf pusat, berupa gangguan motorik, sensorik, panca indera, bahkan kemampuan kognitif. Selain itu efek massa yang ditimbulkan tumor otak akan memberikan masalah serius mengingat tumor berada dalam rongga tengkorak yang pada orang dewasa merupakan suatu ruang tertutup dengan ukuran yang tetap (Wahjoepramono, 2006).

Pada pasien tumor otak, pertumbuhan sel yang tidak perlu secara berlebihan menimbulkan penekanan dan kerusakan pada sel-sel lain di otak dan mengganggu fungsi otak bagian tersebut. Kemudian, tumor tersebut akan menekan ke jaringan sekitar otak, tulang tengkorak, jaringan otak yang sehat dan area sekitar syaraf (Cook & Freedman, 2012). Penyebab timbulnya tumor otak belum sepenuhnya diketahui, namun keganasan sel pada anggota tubuh lainnya, faktor genetik dan pengaruh lingkungan memiliki peran yang tidak kecil pada timbulnya tumor otak (Ayub, 2015).

Saat ini terdapat 4 teknologi yang tergolong baru untuk penanganan pasien kasus tumor otak di Indonesia. Teknologi canggih tersebut adalah bedah Mikroskopik (teknik *blue ray*), terapi radiasi RAPID ARC, metode pemeriksaan PET-CT, dan


metode bedah radiasi dengan *gamma knife*. Bedah mikroskopik dengan teknik *blue ray* yang diadaptasi dari Jerman ini memiliki ketepatan pengangkatan sel tumor semakin tinggi sehingga dapat mengangkat tumor otak lebih banyak. Terapi radiasi RAPID ARC menggunakan penyinaran yang dapat dilakukan hanya dengan 4 menit dan dapat dilakukan dari beragam sudut (hingga 360 sudut) yang akan membuat penyinaran tumor akan lebih tepat. Pemeriksaan *Positron Emission Tomography* (PET) dapat mendeteksi aktivitas metabolik berlebihan seperti sel-sel kanker yang dapat membantu dokter dalam menentukan tingkat keganasan, penyebaran, dan tingkatan stadium secara tepat. Metode bedah radiasi dengan *gamma knife* merupakan penanganan berbasis sinar radiasi yang tidak membutuhkan pembukaan tempurung otak (Wijaya R. , 2017).

## 2.2 *Magnetic Resonance Imaging (MRI)*

MRI merupakan sarana penunjang diagnostik yang sangat penting yang merupakan bagian dari modalitas *imaging* yang didasarkan pada komputer yang memeragakan potongan-potongan tubuh secara tomografi. Berbeda dengan CT yang memerlukan radiasi ionisasi, MRI didasarkan pada interaksi antara gelombang radio dan inti atom hidrogen dalam tubuh oleh adanya medan magnet. Keunggulan MRI yang menonjol dibandingkan CT adalah kemampuannya mendeteksi diferensiasi jaringan lunak dengan lebih baik. Meskipun begitu, prosedur MRI memakan waktu yang lebih lama dibandingkan CT (Rofiky, Rahardjo, & Soeharmanto, 2017).

Teknik penggambaran MRI relatif kompleks karena gambaran yang dihasilkan tergantung pada banyak parameter. Alat tersebut memiliki kemampuan membuat gambaran potongan *coronal*, *aksial*, dan *oblik* tanpa banyak memanipulasi tubuh pasien. Bila pemilihan para-meternya tepat, kualitas gambaran detil tubuh manusia akan tampak jelas sehingga anatomi dan patologi jaringan tubuh dapat dievaluasi secara teliti. (Noyosiswoyo & Suswati, 2004).

Menurut *Neuroradiology Learning Module* oleh *University of Wisconsin School of Medicine and Public Health* terdapat tiga bidang pencitraan yang digunakan oleh MRI yaitu bidang *axial*, *coronal*, dan *sagittal*. Bidang *axial* merupakan gambar melintang yang mewakili irisan dari tubuh. Bidang *coronal* merupakan gambar yang diambil untuk memisahkan bagian depan dari bagian belakang atau biasa disebut tampilan frontal. Bidang *sagittal* adalah bidang yang tegak lurus terhadap bidang *axial* yang memisahkan sisi kiri dan sisi kanan atau disebut juga tampilan lateral. Gambar 2.1 menunjukkan contoh dari tiap potongan.



Sumber : (Neuroradiology Learning Module)


**Gambar 2.1** Bidang *Axial*, *Sagittal*, dan *Coronal*

### 2.3 Segmentasi Citra Digital

Metode pengolahan citra digital terdiri dari dua prinsip yaitu perbaikan penggambaran dari interpretasi tubuh manusia dan pengolahan data citra untuk penyimpanan, transmisi, dan representasi yang digunakan untuk keperluan persepsi alat. Sebuah citra dapat didefinisikan sebagai fungsi dua dimensi  $f(x, y)$ , dimana  $x$  dan  $y$  adalah koordinat spasial dan amplitud dari  $f$  pada sembarang pasangan koordinat  $(x, y)$  disebut *intensity* (intensitas) atau *gray level* (level keabuan) dari citra pada titik tersebut. Segmentasi citra adalah membagi sebuah citra menjadi beberapa region berdasarkan beberapa kriteria. Digitalisasi citra adalah pros-

es mengubah bentuk gambar menjadi bentuk data numerik agar dapat diolah dengan komputer digital. (Gonzales & Woods, 2008)

Pada umumnya citra digital menggunakan model RGB (*red, green, blue*), model CMY (*cyan, magenta, yellow*) dan CMYK (*cyan, magenta, yellow, black*) dan model HSI (*hue, saturation, intensity*). Model RGB dalam satu *pixel* citra masih memuat 3 intensitas warna *red, green* dan *blue* sehingga jika ingin menjadikan satu nilai pada setiap *pixel* maka harus dirubah menjadi citra abu-abu. Pengubahan menjadi citra abu-abu dilakukan agar memudahkan pengolahan data (Ahmad, 2005). Skema warna RGB ditunjukkan oleh unit kubus pada Gambar 2.2.



Sumber : (Gonzales & Woods, 2008)

**Gambar 2.2** Skema Warna RGB dalam Kubus

Citra abu-abu merupakan citra yang hanya memiliki satu nilai pada setiap *pixel*nya, nilai tersebut disebut dengan kadar keabuan (Gonzalez dan Woods, 2002). Citra abu-abu memiliki komposisi *Red* (R), *Green* (G), dan *Blue* (B). Proses perubahan citra berwarna ke dalam citra abu-abu dapat dilakukan dengan pembobotan. Pembobotan ini didasari pada tingkat kepekaan manusia dalam memandang komposisi warna. Persamaan metode pembobotan ini dapat dirumuskan pada persamaan (2.1) (Shih, 2010).

$$gray = 0.299R + 0.587G + 0.114B \quad (2.1)$$

Secara digital suatu *grayscale* berbentuk *array* dua dimensi atau matriks. Tiap elemen pada *array* tersebut menunjukkan in-

tensitas *grayscale* dari pada posisi koordinat yang bersesuaian. Apabila suatu image direpresentasikan dalam 8 bit, pada image terdapat  $2^8$  atau 256 level *grayscale*, biasanya bernilai 0-255 (Gonzales & Woods, 2008) Dimana 0 menunjukkan level intensitas yang paling gelap dan 255 menunjukkan intensitas paling terang. Misalkan suatu citra  $\mathbf{f}(\mathbf{x}, \mathbf{y})$  dengan M baris dan N kolom, maka dapat ditunjukkan oleh persamaan matriks (2.2).

$$\mathbf{f}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & \dots & \dots & f(1,N-1) \\ \dots & \dots & \dots & \dots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (2.2)$$

Salah satu proses yang penting dalam pengenalan objek yang tersaji secara visual (berbentuk gambar) adalah segmentasi (Munir, 2006). Segmentasi objek di dalam citra bertujuan memisahkan wilayah (*region*) objek dengan wilayah latar belakang. Selanjutnya, wilayah objek yang telah tersegmentasi digunakan untuk proses berikutnya seperti deteksi tepi, pengenalan pola dan interpretasi objek (Munir, 2006).

## 2.4 Histogram Citra

Informasi penting mengenai isi citra digital dapat diketahui dengan membuat histogram citra. Histogram citra adalah grafik yang menggambarkan penyebaran nilai-nilai intensitas *pixel* dari suatu citra atau bagian tertentu di dalam citra. Dari sebuah histogram dapat diketahui frekuensi kemunculan nisbi (*relative*) dari intensitas pada citra tersebut. Histogram juga dapat menunjukkan banyak hal tentang kecerahan (*brightness*) dan kontras (*contrast*) dari sebuah gambar. Oleh karena itu histogram adalah alat bantu dalam pengolahan citra baik secara kualitatif maupun kuantitatif (Munir, 2004) .

Jika citra memiliki intensitas *grey scale* yang bernilai 0 hingga 255 maka histogram citra dihitung dengan rumus:

$$h_l = \frac{n_l}{N} ; l = 0, 1, \dots, 255 \quad (0.1)$$


dimana,

$h_l$  = proporsi intensitas derajat keabuan  $l$

$n_l$  = jumlah *pixel* yang memiliki derajat keabuan  $l$

$N$  = jumlah seluruh *pixel* di dalam citra

Histogram citra terbentuk dari plot  $h_l$  versus intensitas. Di bawah ini merupakan histogram citra yang berbentuk diagram batang.



Sumber : (Munir, 2004)

**Gambar 2.3** Histogram Citra

## 2.5 *Gaussian Mixture Model*

Dalam segmentasi citra, analisis *cluster* memberikan algoritma untuk mengelompokkan setiap *pixel* berdasarkan kedekatan atributnya. Beberapa model tradisional seperti *Hierarchical Clustering* dan *Partitioning Algorithm* masih bersifat heuristic dan tidak mempertimbangkan pola atau model dari data. Permasalahan yang kerap timbul dari model tradisional adalah bagaimana menentukan banyak *cluster* optimum, membandingkan antar algoritma, serta penanganan terhadap *noise*. Alternatif model yang dikembangkan adalah *Model Based Clustering*.

*Model Based Clustering* membentuk kelompok berdasarkan statistik dari data. Beberapa kelompok memiliki pola atau distribusi yang bisa sama atau bahkan berbeda-beda, sehingga akan menjadikan model keseluruhannya adalah model *mixture*. Model *mixture* adalah suatu model yang merupakan gabungan dari beberapa sub populasi, tetapi sifat asli setiap sub populasi tersebut tetap dipertahankan (Gelman, Carlin, Stern, Dunson, Vehtari, & Rubin, 2014). Model *mixture* dapat terdiri atas sejumlah kompo-

nen dengan distribusi yang berbeda-beda dengan proporsi tertentu sehingga dapat memberikan gambaran atau deskripsi yang lebih detail dari karakteristik data aslinya.

Secara umum pola distribusi *mixture* dan multi modal dapat didekati dengan formula sebagai berikut (Iriawan, 2001; McLachlan & Bashford, 1988):

$$f(x|\theta, \pi) = \sum_{j=1}^K \pi_j f_j(x|\theta_j) \quad (2.4)$$

dengan

$f(x|\theta, \pi)$ : fungsi densitas distribusi *mixture*,

$p_j(x|\theta_j)$ : fungsi densitas ke- $j$  dari sebanyak  $K$  komponen penyusunan model distribusi *mixture*,

$\theta_j$ : vektor parameter setiap distribusi komponen penyusunan distribusi *mixture*  $(\pi_1, \pi_2, \pi_3, \dots, \sigma_1^2, \sigma_2^2, \sigma_3^2, \dots)$ ,

$\pi$ : vektor parameter proporsi dengan elemen-elemen  $(\pi_1, \pi_2, \dots, \pi_K)$ ,

$\pi_j$ : parameter proporsi komponen distribusi *mixture* dengan

$$\sum_{j=1}^K \pi_j = 1 \text{ serta } 0 \leq \pi_j \leq 1, j=1, 2, \dots, K,$$

$K$ : banyaknya distribusi sebagai komponen penyusunan distribusi *mixture* yang telah ditentukan.

Berbagai metode dikembangkan untuk menaksir parameter *mixture* model diantaranya metode grafik, metode momen, metode *maximum likelihood*, dan metode Bayes. Namun tidak ada satupun metode yang memberikan formula eksplisit dalam menaksir parameter *mixture* model. Metode *maximum likelihood* telah banyak digunakan dalam menaksir parameter *mixture* model dengan fungsi *likelihood* sebagai berikut:

$$L(x|\theta, \pi) = \prod_{i=1}^N f(x_i|\theta_j, \pi_j) = \prod_{i=1}^N \sum_{j=1}^K \pi_j f_j(x_i|\theta_j)$$

Umumnya lebih mudah dicari solusi dengan menggunakan fungsi *log likelihood*-nya:

$$\ell(x|\theta, \pi) = \sum_{i=1}^N \log(f(x_i|\theta_j, \pi_j)) = \prod_{i=1}^N \log\left(\sum_{j=1}^K \pi_j p_j(x_i|\theta_j)\right)$$

Penggunaan *mixture model* dalam pendeskripsian data telah digunakan dalam berbagai disiplin ilmu, seperti Biologi hingga Ekonomi. Dalam dunia kedokteran, *mixture model* sering digunakan dalam klasifikasi hasil MRI otak. *Mixture model* didasarkan pada pernyataan bahwa suatu distribusi dapat dinyatakan dalam campuran beberapa distribusi yang diketahui parameternya, misalnya Gaussian dengan optimasi EM (*expectation maximization*) sehingga menghasilkan klasifikasi elemen distribusi yang disebut “kelas”.

*Gaussian mixture model* (GMM) sering digunakan dalam klasifikasi hasil *magnetic imaging resonance* (MRI), *positron emission tomography* (PET), *computed tomography* (CT), dan hasil *scan* dalam dunia kedokteran lainnya. Pengembangan GMM untuk segmentasi dalam kasus kesehatan dikarenakan GMM dapat diandalkan dalam pemodelan distribusi intensitas citra. Citra yang dihasilkan terlihat homogen pada target ataupun latar belakangnya sehingga menyulitkan diagnosa pasien. Sehingga dibutuhkan segmentasi citra dengan GMM agar hasil MRI dapat dibaca dengan mudah. Sejauh ini penelitian terhadap segmentasi citra khususnya pada data klinis sering menggunakan GMM daripada distribusi yang lain. (Aristophanous, Penney, Martel, & Pelizzari, 2007).

Secara umum GMM dapat ditulis sebagai berikut.:

$$f(x_i|\theta_K) = \frac{\pi_i}{\sqrt{2\pi\sigma_K^2}} e^{-\frac{(x_i - \mu_K)^2}{2\sigma_K^2}}, \theta_K = (\mu_K, \sigma_K) \quad (2.5)$$

Dengan asumsi observasi bersifat independen  $x_i$  maka fungsi *likelihood* untuk parameter  $\Psi$  adalah:



$$L(\Psi) = \prod_{i=1}^N f(x_i | \Psi) = \prod_{i=1}^N \sum_{k=1}^K \frac{\pi_k}{\sqrt{2\pi\sigma_k^2}} e^{-\frac{(x_i - \mu_k)^2}{2\sigma_k^2}} \quad (2.6)$$

Dimana  $\Psi = (\pi_1, \pi_2, \dots, \pi_K, \Theta)$  adalah vektor dari parameter dengan  $\Theta = (\pi_1, \pi_2, \pi_3, \dots, \sigma_1^2, \sigma_2^2, \sigma_3^2, \dots)$  yang merupakan *set of parameter* dari *mixture model* (McLachlan & Peel, 2000).

## 2.6 Algoritma EM (Expectation Maximization) pada Gaussian Mixture Model

Algoritma EM sering digunakan dalam pendekatan komputasi iterative dari estimasi ML (*Maximum Likelihood*) misalnya metode Newton-Raphson atau metode yang lebih rumit lainnya (Kumar, Satoor, & Buck, 2009).

EM dimulai dengan asumsi bahwa  $X$  adalah *incomplete-data*. Asumsi tersebut menyebutkan terdapat sebuah *complete dataset*  $Z = (X, Y)$  dengan  $Y$  adalah variabel laten yang memuat *labeling cluster* dari  $X$  yang memiliki densitas gabungan sebagai berikut

$$p(Z | \Psi) = p(Y | X, \Psi) p(X | \Psi) \quad (2.7)$$

Dengan fungsi gabungan di atas, maka *complete-data* log-likelihood dapat dituliskan sebagai persamaan

$$L(\Psi | Z) = L(\Psi | X, Y) = p(X, Y | \Psi).$$

Diketahui  $X \in \{x_1, x_2, \dots, x_N\}$  adalah data sebanyak  $N$  yang berasal dari distribusi dengan fungsi densitas  $p(x | \Psi)$  dengan parameter  $\Psi$ . Diasumsikan vector data  $x_i$  dengan  $i \in \{1, 2, \dots, N\}$  bersifat independen dan identik berdistribusi normal sehingga membentuk densitas untuk sampel adalah sebagai berikut.

$$p(x | \Psi) = \prod_{i=1}^N p(x_i | \Psi) = L(\Psi | X) \quad (2.8)$$

Fungsi  $L(\Psi | x)$  disebut fungsi likelihood dari parameter. Langkah pertama dalam algoritma EM adalah menurunkan fungsi *likelihood* terhadap mean  $\mu_j$  dari komponen Gaussian.

$$\frac{\partial L(\Psi)}{\partial \mu_j} = - \sum_{i=1}^N \frac{\pi_j f(x_i | \mu_j, \sigma_j)}{\sum_{j=1}^K \pi_j f(x_i | \mu_j, \sigma_j)} \frac{x_i - \mu_j}{\sigma_j^2} = 0 \quad (2.9)$$

dimana  $\sum_{l=1}^K \pi_l f(x_i | \mu_l, \sigma_l)$  merupakan variabel laten  $y_{ij}$ , dengan ekspektasi probabilitas posterior:

$$y_{ij}^{(t)} = \frac{\pi_j^{(t)} f(x_i | \mu_j^{(t)}, \Sigma_j^{(t)})}{\sum_{j=1}^K \pi_j^{(t)} f(x_i | \mu_j^{(t)}, \Sigma_j^{(t)})} \quad (2.10)$$

dengan  $t$  adalah langkah iterasi. Solusi dari  $\partial L(\mu, \sigma, \pi | x) / \partial \mu_j = 0$  menghasilkan nilai minimum dari  $\mu_j$  pada langkah iterasi ke  $(t + 1)$ :

$$\mu_j^{(t+1)} = \frac{\sum_{i=1}^N y_{ij}^{(t)} x_i}{\sum_{i=1}^N y_{ij}^{(t)}} \quad (2.11)$$

Selanjutnya, jika fungsi *likelihood* diturunkan terhadap  $\sigma_j$ , maka didapatkan:

$$\left[ \sigma_j^2 \right]^{(t+1)} = \frac{\sum_{i=1}^N y_{ij}^{(t)} (x_i - \mu_j^{(t+1)})^2}{\sum_{i=1}^N y_{ij}^{(t)}} \quad (2.12)$$

Setelah itu menurunkan fungsi *likelihood*  $L(\Psi | x)$  terhadap  $\pi_j$  dimana harus memenuhi  $0 \leq \pi_j \leq 1$  dan  $\sum_{j=1}^K \pi_j = 1$ . Hal ini

dapat dicapai dengan menggunakan sebuah *Lagrange multiplier*  $\eta$  dan memaksimumkan turunan berikut.

$$\frac{\partial}{\partial \pi_j} \left[ L(\Psi | x) - \eta \left( \sum_{j=1}^K \pi_j - 1 \right) \right] = 0 \quad (2.13)$$

dimana selanjutnya didapatkan:

$$\sum_{i=1}^N \frac{f(x_i | \mu_j, \sigma_j)}{\sum_{l=1}^K \pi_l f(x_i | \mu_l, \sigma_l)} - \eta = 0 \quad (2.14)$$

Setelah kedua sisi dikalikan dengan  $\pi_j$  dan digunakan domain  $0 \leq \pi_j \leq 1$  dan  $\sum_{j=1}^K \pi_j = 1$ , maka diperoleh  $\eta = N$ . Dengan demikian, untuk mengeliminasi  $\eta$  dan menyusun kembali turunan terhadap  $\pi_j$  didapatkan:

$$\pi_j^{(t+1)} = \frac{1}{N} \sum_{i=1}^N y_{ij}^{(t)} \quad (2.15)$$

(Nguyen, 2011)

Secara umum algoritma EM untuk *Gaussian Mixture Model* dijelaskan pada Algoritma 2.1.

**Algoritma 2.1** Algoritma EM untuk Segmentasi dengan GMM

1. Inisialisasi parameter *mean*  $\mu_j$ , nilai varians  $\sigma_j^2$ , dan distribusi prior  $\pi_j$ .
2. E-Step : Menghitung nilai  $y_{ij}$  menggunakan nilai parameter awal menggunakan persamaan (2.10)
3. M-Step : Estimasi ulang parameter *mean*  $\mu_j$ , nilai varians  $\sigma_j^2$ , dan distribusi prior  $\pi_j$  dengan cara *update* masing-masing parameter menggunakan persamaan (2.11), (2.12), dan (2.13).

4. Evaluasi fungsi *log-likelihood* dan periksa konvergensi dari fungsi *log-likelihood* dan nilai parameter. Jika kriteria konvergen nilai *error* <0,0001 belum terpenuhi maka ulangi langkah ke-2.

## 2.7 *Silhouette Coefficient*

Metode yang sering digunakan untuk menghitung *silhouette coefficient* adalah *cohesion* dan *separation*. Berikut adalah langkah-langkah menghitung *silhouette coefficient*.

1. Untuk objek ke-*i*, hitung rata-rata jarak objek terhadap objek lain di dalam klaster. Nilai ini disebut  $a_i$ .
2. Untuk objek ke-*i* dan klaster yang tidak mengandung objek, hitung rata-rata jarak objek terhadap objek dari klaster yang diberikan. Hitung nilai minimum dari rata-rata jarak tersebut untuk semua klaster, sehingga disebut  $b_i$ .
3. Untuk objek ke-*i*, nilai *silhouette coefficient* adalah  $s_i = (b_i - a_i) / \max(a_i, b_i)$

*Silhouette coefficient* bernilai antara -1 dan 1. Nilai yang semakin mendekati 1 menandakan semakin tepatnya data tersebut berada dalam klaster yang ditempatinya. Nilai SI bernilai negatif menandakan data tersebut tidak tepat didalam klaster yang ia tempati. Nilai SI bernilai=0 menandakan data tersebut berada di perbatasan antara dua klaster. (Tan, Steinbach, & Kumar, 2005)

## BAB III METODOLOGI PENELITIAN

### 3.1 Sumber Data

Data yang digunakan adalah data sekunder yaitu citra MRI data rekam medis di Rumah Sakit Umum Daerah (RSUD) Dr. Soetomo Surabaya. Data rekam medis yang digunakan merupakan rekomendasi dari sudut pandang medis. Citra MRI yang digunakan adalah hasil *scan* MRI pasien dengan ID 12565918 pada tanggal 17 Februari 2017 *slice axial* (28 *slice*) , *slice coronal* (22 *slice*), dan *slice sagittal* (22 *slice*).

### 3.2 Variabel Penelitian

Bagian ini akan menjelaskan variabel penelitian dan struktur data yang digunakan dalam penelitian ini. Pada penelitian ini variabel yang digunakan ditampilkan dalam Tabel 3.1.

**Tabel 3.1** Variabel Penelitian

Variabel	Keterangan	Skala data
<i>Grayscale</i> (x)	Besarnya intensitas keabuan di tiap-tiap <i>pixel</i> citra MRI	Interval

Variabel *Grayscale* mewakili intensitas keabuan di tiap pixel citra MRI. Intensitas citra MRI berbentuk matriks berukuran  $p \times p$ . Elemen matriks merupakan intensitas keabuan yang bernilai antara 0 hingga 255 sehingga membentuk struktur data seperti pada Tabel 3.2.

**Tabel 3.2** Struktur Data

Baris $i$	Kolom $j$	<i>Grayscale</i> (x)
1	1	$x_{(1,1)}$
1	2	$x_{(1,2)}$
$\vdots$	$\vdots$	$\vdots$
1	$p$	$x_{(1,p)}$
2	1	$x_{(2,1)}$
2	2	$x_{(2,2)}$
$\vdots$	$\vdots$	$\vdots$
2	$p$	$x_{(2,p)}$

**Tabel 3.2** Struktur Data (Lanjutan)

$\vdots$	$\vdots$	$\vdots$
$p$	1	$x_{(2,1)}$
$p$	2	$x_{(2,2)}$
$\vdots$	$\vdots$	$\vdots$
$p$	$p$	$x_{(p,p)}$

Struktur data ini akan digunakan untuk analisis klastering yang melibatkan tingkat intensitas *grayscale* dan frekuensinya di dalam suatu citra.


### 3.3 Langkah Analisis

Penelitian ini memiliki target dapat membentuk 3 dimensi dari hasil citra MRI. Maka dari itu perlu ditentukan banyaknya kluster yang dapat menggambarkan objek dengan tepat. pemilihan banyaknya kluster didasarkan pada analisis subjektif dari peneliti sehingga didapatkan *region of interest* (ROI) yang optimal. Tahapan yang dilakukan dalam penelitian ini setelah didapat data citra rekam medis MRI adalah sebagai berikut.

1. Input data citra MRI.
2. Segmentasi citra MRI menggunakan *Gaussian Mixture Model*.
3. Menggabungkan hasil segmentasi citra untuk semua *sequence* untuk membentuk citra 3 dimensi.
4. Membuat kesimpulan.

### 3.4 Diagram Alir

Berikut adalah diagram alir penyelesaian segmentasi citra MRI tumor otak untuk membentuk citra 3 dimensi.



**Gambar 3.1** Diagram Alir

*(Halaman ini sengaja dikosongkan)*




## BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini akan dilakukan *clustering* dengan menggunakan *Gaussian Mixture Model* dengan pendekatan *Expectation Maximization* (EM-GMM) untuk menyelesaikan permasalahan hasil segmentasi citra MRI tumor otak. Pembahasan diawali dengan *clustering* hasil citra MRI lalu memodelkannya menjadi model 3 dimensi.

### 4.1 Karakteristik Hasil Citra MRI


Statistik deskriptif dengan histogram citra digunakan untuk mengetahui karakteristik dari hasil citra MRI pada bagian *axial*, *coronal*, dan *sagittal*. Histogram citra menunjukkan pola dari intensitas keabuan (*grayscale*) sehingga dapat diduga berapa klaster yang akan digunakan.



**Gambar 4.1** Histogram Citra *Slice Axial* ke-19


Gambar 4.1 menunjukkan histogram dari salah satu *slice* dari bagian *axial* yaitu pada *slice* ke-19 di mana bentuk tumor terlihat jelas. Histogram di atas diduga memiliki 4 puncak dimana pada intensitas gelap mendekati nol terdapat puncak yang paling tinggi. Pada intensitas tengah di antara 50 hingga 100 juga terbentuk puncak. Namun banyaknya puncak yang terlihat belum

tentu sesuai dengan banyaknya klaster yang digunakan untuk membentuk citra 3 dimensi sehingga perlu ditinjau lebih jauh.



**Gambar 4.2** Histogram Citra *Slice Coronal* ke-10

Gambar 4.2 merupakan histogram citra dari *coronal slice* yaitu *slice* ke-10. Pada *slice* ini bentuk tumor terlihat dengan jelas. Terlihat bahwa terdapat puncak yang tinggi pada intensitas gelap serta pada intensitas antara 50 dan 100. Ada 4 puncak yang terlihat secara sekilas.



**Gambar 4.3** Histogram Citra *Slice Sagittal* ke-16

Histogram dari *slice* ke-16 dari bagian *sagittal* ditunjukkan oleh Gambar 4.3. Pada histogram terlihat bahwa banyak piksel memiliki intensitas gelap. Terlihat adanya 5 puncak dari histo-

gram ini. Terdapat puncak tinggi yang lain yaitu di antara intensitas 50 hingga 100.

## 4.2 Hasil *Clustering* Hasil Citra MRI Menggunakan *Gaussian Mixture Model* dengan Pendekatan *Expectation Maximization* (EM-GMM)

Pada analisa ini data akan dilakukan *clustering* menggunakan EM-GMM sehingga hasil citra MRI terbagi menjadi beberapa klaster. Area tumor dari hasil citra MRI akan dijadikan *region of interest* (ROI) sehingga saat pembentukan model 3 dimensi dapat memperjelas letak dan bentuk tumornya. Berikut adalah hasil *clustering* dari beberapa *slice* dari masing-masing bagian yang dimana gambar tumor tampak jelas. Jumlah klaster disamakan untuk semua bagian agar memudahkan saat proses pembentukan model 3 dimensi.

### 4.2.1 Hasil *Clustering* Hasil Citra MRI *Slice Axial* Menggunakan EM-GMM

*Clustering* menggunakan EM-GMM akan menghasilkan beberapa *output* seperti parameter-parameter dari GMM (seperti  $\mu$ ,  $\pi$ , dan  $\sigma^2$ ), gambar hasil *clustering*, dan letak ROI. Berikut adalah *output* yang dihasilkan pada tahap *clustering*.

**Tabel 4.1** Parameter  $\mu$  dari Citra *Slice Axial*

<i>Slice</i>	$\mu_1$	$\mu_2$	$\mu_3$	$\mu_4$	$\mu_5$	$\mu_6$
1	5,419	25,731	55,466	81,226	87,537	56,110
2	4,068	47,964	93,610	121,702	148,810	140,931
3	3,378	52,602	97,508	131,488	160,613	178,967
4	3,425	55,417	95,850	136,558	172,377	195,071
5	3,305	53,809	100,210	140,365	177,028	191,148
6	2,703	46,161	97,125	135,293	158,052	148,504
7	3,133	53,223	95,514	136,350	170,710	185,317
8	1,909	35,383	79,348	113,175	101,316	116,210
9	3,149	69,492	58,153	134,776	173,835	193,769
10	3,007	69,902	56,094	133,452	171,769	199,601
11	2,484	59,091	48,849	125,624	165,727	125,181
12	2,338	59,613	46,448	120,345	163,435	156,102
13	2,208	57,625	43,202	116,506	160,579	147,423

**Tabel 4.1** Parameter  $\mu$  dari Citra *Slice Axial* (Lanjutan)

<i>Slice</i>	$\mu_1$	$\mu_2$	$\mu_3$	$\mu_4$	$\mu_5$	$\mu_6$
14	2,087	58,680	43,607	122,678	161,936	143,406
15	2,170	59,491	46,193	127,454	166,105	145,733
16	2,096	58,414	47,565	128,639	164,863	142,503
17	2,041	57,292	46,319	123,481	159,061	124,258
18	2,049	60,505	49,229	121,113	162,376	143,117
19	2,506	68,424	55,430	132,054	166,639	188,35
20	2,657	73,956	58,662	128,104	167,435	197,766
21	2,700	72,857	57,414	126,957	165,756	189,488
22	2,224	64,487	54,844	127,410	155,996	159,872
23	2,575	70,606	59,523	134,076	168,674	184,440
24	2,654	71,952	59,047	124,346	167,087	184,886
25	2,995	76,647	62,478	123,320	167,785	194,967
26	2,935	65,997	74,906	135,070	171,087	187,591
27	2,876	60,766	94,262	143,925	172,631	186,369
28	2,940	53,472	100,182	140,068	172,281	193,960

**Tabel 4.2** Parameter  $\pi$  dari Citra *Slice Axial*

<i>Slice</i>	$\pi_1$	$\pi_2$	$\pi_3$	$\pi_4$	$\pi_5$	$\pi_6$
1	0,444	0,441	0,064	0,014	0,011	0,023
2	0,483	0,395	0,088	0,021	0,006	0,004
3	0,472	0,340	0,112	0,052	0,015	0,007
4	0,457	0,331	0,099	0,059	0,038	0,015
5	0,437	0,393	0,068	0,050	0,035	0,013
6	0,438	0,439	0,052	0,039	0,018	0,010
7	0,424	0,444	0,046	0,040	0,029	0,014
8	0,406	0,467	0,085	0,020	0,014	0,004
9	0,386	0,246	0,262	0,064	0,026	0,013
10	0,383	0,324	0,210	0,049	0,022	0,009
11	0,387	0,340	0,219	0,026	0,010	0,015
12	0,381	0,383	0,186	0,028	0,011	0,008
13	0,379	0,399	0,171	0,027	0,011	0,008
14	0,378	0,405	0,171	0,025	0,010	0,008
15	0,383	0,395	0,179	0,022	0,010	0,008
16	0,389	0,381	0,192	0,019	0,009	0,007
17	0,398	0,364	0,200	0,019	0,008	0,009
18	0,407	0,341	0,211	0,022	0,009	0,007

**Tabel 4.2** Parameter  $\pi$  dari Citra *Slice Axial* (Lanjutan)

<i>Slice</i>	$\pi_1$	$\pi_2$	$\pi_3$	$\pi_4$	$\pi_5$	$\pi_6$
19	0,421	0,322	0,214	0,024	0,010	0,006
20	0,438	0,304	0,210	0,024	0,014	0,007
21	0,462	0,280	0,205	0,027	0,015	0,008
22	0,485	0,241	0,226	0,026	0,011	0,008
23	0,514	0,209	0,217	0,033	0,016	0,008
24	0,546	0,173	0,201	0,045	0,021	0,012
25	0,584	0,137	0,183	0,052	0,027	0,015
26	0,628	0,200	0,090	0,039	0,024	0,015
27	0,681	0,200	0,047	0,036	0,026	0,008
28	0,732	0,136	0,046	0,038	0,032	0,012


**Tabel 4.3** Parameter  $\sigma^2$  dari Citra *Slice Axial*

<i>Slice</i>	$\sigma_1^2$	$\sigma_2^2$	$\sigma_3^2$	$\sigma_4^2$	$\sigma_5^2$	$\sigma_6^2$
1	6,000	135,000	91,100	93,800	1618,300	344,700
2	5,500	360,800	238,500	143,600	121,400	1146,300
3	4,824	514,694	314,631	214,535	214,175	458,338
4	5,0357	620,448	464,254	281,007	190,707	160,205
5	4,7261	629,442	615,692	309,470	184,490	266,376
6	4,2127	420,001	403,348	200,338	86,318	465,060
7	5,1753	528,801	843,5616	314,963	201,106	198,721
8	3,300	190,200	332,000	96,700	215,700	3154,300
9	5,044	23,627	868,024	372,041	276,668	211,676
10	4,668	27,907	902,749	358,637	198,320	219,197
11	3,822	19,041	594,160	375,418	109,453	911,643
12	3,584	20,535	562,259	412,357	139,214	651,462
13	3,577	19,784	513,633	422,653	141,648	893,846
14	3,175	20,212	556,194	384,385	125,128	839,553
15	3,494	21,704	589,433	391,482	137,756	857,797
16	3,198	21,357	636,873	329,314	103,823	977,239
17	3,200	24,500	612,100	304,800	103,100	1101,700
18	3,020	26,454	688,872	300,776	123,589	784,651
19	3,445	29,065	844,471	262,546	241,313	265,348
20	3,460	33,961	938,756	572,496	204,254	192,893
21	3,447	35,563	842,141	564,906	224,367	314,911
22	2,834	24,311	719,321	301,356	110,551	483,306
23	2,925	27,344	784,886	432,085	203,097	505,424


**Tabel 4.3** Parameter  $\sigma^2$  dari Citra *Slice Axial* (Lanjutan)

<i>Slice</i>	$\sigma_1^2$	$\sigma_2^2$	$\sigma_3^2$	$\sigma_4^2$	$\sigma_5^2$	$\sigma_6^2$
24	2,692	28,282	678,976	528,412	222,179	304,959
25	2,815	26,547	697,622	576,324	205,312	202,785
26	2,716	867,536	19,314	420,047	239,722	347,424
27	2,576	611,555	584,008	275,086	180,076	419,462
28	2,484	553,287	364,755	263,661	208,337	230,382

Pada bagian *axial* ini terdapat 28 *slice* citra MRI. Masing-masing *slice* dilakukan *clustering* agar mendapatkan ROI yang dapat menjelaskan objek. *Slice axial* dikelompokkan menjadi 6 klaster berdasarkan *Gaussian mixture model*. Tiap klaster memiliki parameter-parameter seperti  $\mu$ ,  $p$ , dan  $\sigma^2$ . Parameter dari masing-masing *slice* dapat dilihat di Tabel 4.1, Tabel 4.2, dan Tabel 4.3.

**Gambar 4.4** Histogram 6 Klaster Citra *Slice Axial* ke-19


Gambar 4.4 menunjukkan histogram *mixture model* yang membentuk 6 klaster untuk *axial slice* ke-19. Bentuk histogram dari hasil *clustering* mendekati histogram citra. Tiap puncak memiliki parameter masing-masing seperti dalam tabel-tabel di atas.




**Gambar 4.5** Hasil Citra *Slice Axial* ke-19 (a) Gambar Asli  
(b) Hasil *Clustering*

Gambar 4.5 adalah gambar dari *axial slice* ke-19. Gambar 4.5 (a) merupakan gambar asli hasil citra MRI sedangkan Gambar 4.5 (b) adalah hasil citra MRI yang sudah dilakukan *clustering* sebanyak 6 klaster. Menurut analisis subjektif peneliti, area tumor membentuk klaster yang berbeda dengan area otak dan pembengkakan tumornya. Namun pada klaster yang sama dengan klaster di mana area tumor berada terdapat area tengkorak yang masuk menjadi anggota klaster. Hal ini dikarenakan *grayscale* area tumor dan area tengkorak memiliki kemiripan sehingga menjadi klaster yang sama. Klaster dari tumor otak pada *slice* ini terdapat di klaster ke-4.

**NROI-Non region of interest**




**ROI-region of interest**



**Gambar 4.6** NROI dan ROI dari Citra *Slice Axial* ke-19

Setelah dilakukan *clustering* selanjutnya dicari kluster mana yang merupakan *region of interest* atau ROI. Gambar 4.6 menunjukkan bagian dari ROI dan Non-ROI. Kluster 4 merupakan ROI karena mengandung area tumor. Sedangkan Non-ROI merupakan area lain selain area tumor dan anggota kluster 4.



**Gambar 4.7** Perbandingan Nilai *Silhouette Index* Kluster 5 hingga 8 *Slice Axial*

Gambar 4.7 menunjukkan evaluasi hasil *clustering* dengan *Silhouette Index* (SI). *Noise* dari citra hasil MRI memiliki intensitas yang bermacam-macam sehingga harus menggunakan kluster yang cukup banyak. Maka dari itu, penulis menggunakan 5 hingga 8 kluster untuk mengetahui kebaikan klasifikasi. Nilai SI yang cukup tinggi dihasilkan oleh 5 kluster dan 6 kluster. 5 kluster memiliki nilai SI yang lebih besar daripada 6 kluster namun pada *sequence* yang terdapat gambar tumor kira-kira *sequence* 17 hingga 21 nilai SI yang tinggi dihasilkan 6 kluster. Selain itu ROI yang didapatkan oleh klasifikasi 5 kluster terlalu luas sehingga area selain tumor pun masih masuk dalam ROI. Dengan pertimbangan tersebut, maka dipilih 6 kluster adalah kluster yang cocok mengelompokkan intensitas keabuan pada hasil citra MRI *slice axial*.



#### 4.2.2 Hasil *Clustering* Hasil Citra MRI *Slice Coronal* Menggunakan EM-GMM

Terdapat beberapa *output* yang dihasilkan dalam proses *clustering* yaitu  $\mu$ ,  $\pi$ , dan  $\sigma^2$  yang merupakan parameter dari GMM, gambar hasil *clustering*, serta hasil NROI dan ROI. Berikut adalah *output* yang dihasilkan pada proses *clustering*.

**Tabel 4.4** Parameter  $\mu$  dari Citra *Slice Coronal*

<i>Slice</i>	$\mu_1$	$\mu_2$	$\mu_3$	$\mu_4$	$\mu_5$	$\mu_6$
0	2,720	55,780	89,953	137,637	173,783	176,247
1	2,571	57,708	97,452	141,456	163,609	183,178
2	2,435	55,238	101,120	136,814	157,754	154,208
3	2,720	59,134	99,944	135,795	166,793	162,345
4	2,988	64,281	88,279	138,294	174,639	181,964
5	3,441	70,719	78,170	127,137	173,506	200,753
6	3,279	68,649	55,433	107,519	158,951	188,599
7	3,178	67,824	43,672	104,554	159,027	176,304
8	3,333	68,200	56,745	111,205	162,657	182,389
9	3,583	68,675	75,474	125,982	167,883	192,654
10	3,553	73,079	68,433	119,992	168,465	185,072
11	3,445	70,987	71,976	105,305	153,292	180,085
12	3,582	68,341	71,087	106,239	156,391	190,278
13	3,713	65,640	74,209	107,086	158,147	192,916
14	3,582	68,453	58,869	107,754	160,789	184,537
15	3,254	67,632	56,807	120,095	157,306	186,814
16	3,472	70,395	58,893	125,758	166,524	201,861
17	3,352	73,351	58,028	121,030	167,507	201,724
18	2,895	62,416	51,781	113,374	154,992	167,072
19	3,170	73,614	55,057	127,064	176,492	196,111
20	2,832	66,069	49,586	122,468	169,332	167,981
21	2,526	55,144	114,396	144,184	165,573	162,282

**Tabel 4.5** Parameter  $\pi$  dari Citra *Slice Coronal*

<i>Slice</i>	$\pi_1$	$\pi_2$	$\pi_3$	$\pi_4$	$\pi_5$	$\pi_6$
0	0,587	0,254	0,073	0,046	0,028	0,009
1	0,551	0,310	0,059	0,048	0,023	0,006
2	0,524	0,342	0,056	0,046	0,022	0,007
3	0,489	0,378	0,055	0,045	0,021	0,010
4	0,461	0,389	0,063	0,049	0,024	0,012

**Tabel 4.5** Parameter  $\pi$  dari Citra *Slice Coronal* (Lanjutan)

5	0,424	0,288	0,192	0,048	0,028	0,017
6	0,416	0,220	0,205	0,102	0,034	0,021
7	0,402	0,279	0,163	0,105	0,029	0,020
8	0,388	0,219	0,255	0,091	0,025	0,018
9	0,375	0,306	0,213	0,057	0,028	0,017
10	0,367	0,207	0,303	0,081	0,024	0,015
11	0,362	0,322	0,195	0,081	0,024	0,013
12	0,364	0,335	0,213	0,058	0,017	0,011
13	0,370	0,350	0,196	0,051	0,019	0,011
14	0,380	0,228	0,310	0,050	0,018	0,010
15	0,372	0,254	0,299	0,046	0,016	0,008
16	0,377	0,260	0,285	0,051	0,016	0,008
17	0,378	0,279	0,263	0,049	0,019	0,009
18	0,393	0,274	0,250	0,050	0,017	0,012
19	0,411	0,263	0,235	0,053	0,023	0,011
20	0,439	0,233	0,236	0,054	0,023	0,012
21	0,467	0,441	0,031	0,032	0,015	0,009


**Tabel 4.6** Parameter  $\sigma^2$  dari Citra *Slice Coronal*

<i>Slice</i>	$\sigma_1^2$	$\sigma_2^2$	$\sigma_3^2$	$\sigma_4^2$	$\sigma_5^2$	$\sigma_6^2$
0	2,802	738,901	495,034	233,059	122,926	485,714
1	2,915	630,838	690,443	250,293	78,279	646,728
2	2,800	461,200	569,200	257,600	72,500	1065,300
3	2,925	555,918	802,931	271,142	84,057	367,560
4	3,205	566,613	814,558	234,781	174,682	246,838
5	3,200	1259,400	49,500	502,400	251,600	158,300
6	3,648	31,931	807,115	475,116	289,791	196,840
7	3,843	76,366	627,332	521,525	315,768	314,674
8	3,679	23,668	829,514	599,021	382,092	290,444
9	4,020	850,719	43,814	252,971	283,059	224,648
10	4,096	19,416	841,502	378,747	275,105	365,827
11	4,000	1053,400	24,100	228,700	179,000	339,200
12	4,500	1078,900	22,200	156,100	280,600	402,700
13	5,191	970,317	19,327	239,150	281,867	491,561
14	5,392	16,365	724,283	420,289	253,151	613,302
15	4,363	19,667	642,773	433,756	205,371	545,156

**Tabel 4.6** Parameter  $\sigma^2$  dari Citra *Slice Coronal* (Lanjutan)


<i>Slice</i>	$\sigma_1^2$	$\sigma_2^2$	$\sigma_3^2$	$\sigma_4^2$	$\sigma_5^2$	$\sigma_6^2$
16	4,564	14,410	641,439	373,065	286,142	514,055
17	4,125	17,400	646,451	363,287	227,768	370,651
18	3,387	11,720	565,650	334,586	176,358	672,649
19	3,690	17,123	648,575	417,864	209,118	315,695
20	3,161	10,546	501,191	498,760	194,496	486,281
21	2,950	320,610	159,152	174,240	107,152	405,646

Tabel 4.4, Tabel 4.5, dan Tabel 4.6 menunjukkan parameter-parameter yang dihasilkan oleh tahap *clustering* dari *slice coronal*. Tabel 4.4 berisi parameter  $\mu$ , Tabel 4.5 berisi parameter  $p$ , dan Tabel 4.5 berisi parameter  $\sigma^2$  dari masing-masing *slice*. Pada Tabel 4.5 terlihat bahwa kluster 1 mendominasi proporsi, terlihat bahwa proporsinya selalu lebih besar daripada kluster-kluster yang lain. Hal itu dikarenakan karena hasil citra MRI didominasi oleh warna hitam dengan *grayscale* 0.

**Gambar 4.8** Histogram 6 Kluster Citra *Slice Coronal* ke-10

Gambar 4.8 menunjukkan histogram *mixture model* yang membentuk 6 kluster untuk *slice coronal* ke-10. Enam puncak yang terbentuk dapat menangkap bentuk dari histogram citra. untuk *slice* ke-10 parameter GMM-nya adalah  $\mu_1=3,553297$ ,  $\mu_2=73,07929$ ,  $\mu_3=68,43378$ ,  $\mu_4=119,9925$ ,  $\mu_5=168,465$ ,  $\mu_6=185,0728$ ,  $\pi_1=0,367138$ ,  $\pi_2=0,20742$ ,  $\pi_3=0,303886$ ,


$\pi_4=0,081553$ ,  $\pi_5=0,024879$ ,  $\pi_6=0,015124$ ,  $\sigma_1^2=4,0967$ ,  $\sigma_2^2=19,4162$ ,  $\sigma_3^2=841,5028$ ,  $\sigma_4^2=378,7471$ ,  $\sigma_5^2=275,1054$ , dan  $\sigma_6^2=365,8272$ .




**Gambar 4.9** Hasil Citra *Slice Coronal* ke-10 (a) Gambar Asli  
(b) Hasil *Clustering*

Gambar 4.9 (a) adalah gambar asli hasil citra MRI dari *coronal slice* ke-10 sedangkan Gambar 4.8 (b) adalah hasil citra MRI yang dikelompokkan dengan 6 klaster. Area tumor berada pada klaster ke-4. Selain area tumor terdapat juga area lain yang menjadi anggota klaster 4 karena memiliki *grayscale* yang serupa.

**NROI-Non region of interest**




**ROI-region of interest**



**Gambar 4.10** NROI dan ROI dari Citra *Slice Coronal* ke-10

*Region of interest* atau ROI merupakan area yang menjadi fokus dimana dalam hal ini adalah area tumor. Gambar 4.9 menunjukkan bagian dari ROI dan Non-ROI pada *slice coronal*

ke-10. ROI yang dipilih adalah kluster 4 dimana area tumor berada. Non-ROI adalah selain anggota kluster 4 termasuk area otak.



**Gambar 4.11** Perbandingan Nilai *Silhouette Index* Klaster 5 hingga 8 *Slice Coronal*

Evaluasi hasil *clustering* dengan *Silhouette Index* ditunjukkan pada Gambar 4.11. Terlihat pada gambar, klasifikasi dengan menggunakan sebanyak 5 klaster memiliki SI yang cukup tinggi untuk semua *slice coronal*, namun sama seperti *slice axial*, area ROI yang dihasilkan masih terlalu luas sehingga area seperti garis-garis otak atau tulang tengkorak masih masuk sebagai anggota klaster ROI. Maka dipilih klaster yang juga memiliki nilai SI cukup tinggi, yaitu klaster 6 untuk klasifikasi piksel dalam *slice coronal*.

#### 4.2.3 Hasil *Clustering* Hasil Citra MRI *Slice Sagittal* Menggunakan EM-GMM

Hasil dari *clustering* menggunakan EM-GMM adalah parameter-parameter dari GMM ( $\mu$ ,  $p$ , dan  $\sigma^2$ ), gambar hasil *clustering*, dan letak ROI ditunjukkan dengan tabel dan gambar di bawah ini. Berikut adalah *output* yang dihasilkan pada tahap *clustering*.

**Tabel 4.7** Parameter  $\mu$  dari Citra *Slice Sagittal*

<i>Slice</i>	$\mu_1$	$\mu_2$	$\mu_3$	$\mu_4$	$\mu_5$	$\mu_6$
0	2,594	56,753	77,122	126,115	164,169	199,808
1	2,879	61,468	85,582	129,987	173,047	213,608
2	2,551	73,088	53,526	118,487	167,375	196,895
3	2,492	72,017	56,845	126,828	168,522	192,211
4	2,386	64,273	56,738	120,672	159,762	184,958
5	2,593	69,545	54,237	116,094	158,511	194,946
6	2,799	67,532	56,497	124,332	159,660	201,866
7	2,711	68,192	54,856	117,664	159,147	200,031
8	2,808	67,375	60,888	119,152	169,316	214,092
9	2,893	66,266	52,350	111,785	157,992	201,588
10	2,773	61,462	28,703	87,341	138,039	189,733
11	2,855	66,758	57,790	123,219	155,795	198,528
12	2,572	60,110	64,502	127,966	158,691	196,014
13	2,551	61,702	69,847	133,700	166,323	215,522
14	2,573	62,681	54,542	117,896	154,732	203,429
15	2,523	64,288	49,295	109,356	152,455	202,715
16	2,510	66,301	55,665	122,430	162,729	212,966
17	2,530	69,650	55,110	124,654	158,437	208,407
18	2,547	68,812	54,958	125,334	163,528	202,010
19	2,535	70,771	44,583	107,132	160,432	189,814
20	2,816	74,584	51,377	111,441	154,440	191,652
21	2,841	49,176	79,364	120,171	166,089	195,334

**Tabel 4.8** Parameter  $\pi$  dari Citra *Slice Sagittal*

<i>Slice</i>	$\pi_1$	$\pi_2$	$\pi_3$	$\pi_4$	$\pi_5$	$\pi_6$
0	0,453	0,267	0,139	0,090	0,032	0,016
1	0,388	0,295	0,187	0,077	0,030	0,019
2	0,336	0,217	0,280	0,104	0,040	0,020
3	0,300	0,244	0,295	0,096	0,049	0,014
4	0,270	0,260	0,351	0,079	0,026	0,012
5	0,251	0,301	0,328	0,074	0,028	0,015
6	0,237	0,313	0,342	0,064	0,026	0,014
7	0,212	0,292	0,388	0,068	0,025	0,013
8	0,188	0,286	0,432	0,054	0,026	0,012
9	0,191	0,285	0,393	0,092	0,023	0,012
10	0,166	0,407	0,197	0,156	0,054	0,016
11	0,181	0,280	0,456	0,047	0,023	0,009


**Tabel 4.8** Parameter  $\pi$  dari Citra *Slice Sagittal* (Lanjutan)

<i>Slice</i>	$\pi_1$	$\pi_2$	$\pi_3$	$\pi_4$	$\pi_5$	$\pi_6$
12	0,177	0,527	0,238	0,025	0,022	0,012
13	0,176	0,514	0,248	0,027	0,022	0,010
14	0,217	0,288	0,399	0,059	0,025	0,010
15	0,236	0,320	0,317	0,088	0,027	0,010
16	0,251	0,284	0,363	0,066	0,024	0,010
17	0,276	0,261	0,330	0,088	0,030	0,011
18	0,306	0,233	0,317	0,091	0,039	0,011
19	0,352	0,216	0,249	0,128	0,037	0,014
20	0,410	0,174	0,262	0,093	0,035	0,023
21	0,481	0,214	0,138	0,106	0,041	0,016

**Tabel 4.9** Parameter  $\sigma^2$  dari Citra *Slice Sagittal*

<i>Slice</i>	$\sigma_1^2$	$\sigma_2^2$	$\sigma_3^2$	$\sigma_4^2$	$\sigma_5^2$	$\sigma_6^2$
0	2,714	794,412	27,968	273,889	272,732	180,523
1	2,905	848,098	24,336	323,106	369,855	267,428
2	2,669	19,069	716,788	379,726	324,072	156,740
3	2,918	18,007	773,827	452,841	167,531	457,971
4	3,115	13,710	746,686	367,313	148,054	382,187
5	3,443	21,608	655,419	385,681	298,705	363,136
6	4,352	23,388	763,853	463,634	311,150	330,917
7	4,656	19,621	662,303	474,156	290,636	331,229
8	4,810	12,692	795,440	542,921	277,680	237,470
9	5,316	24,302	615,136	482,756	358,515	323,869
10	4,565	51,204	255,063	221,481	367,452	521,634
11	5,361	24,513	829,946	629,493	186,886	340,276
12	4,257	796,597	14,795	530,782	175,068	335,281
13	4,127	858,453	33,232	426,918	284,453	255,969
14	4,042	20,076	697,392	504,253	236,182	299,404
15	3,635	43,939	615,235	494,692	251,694	321,223
16	3,206	22,866	674,789	436,616	281,801	317,766
17	3,012	29,457	792,042	456,975	190,610	380,264
18	2,743	17,792	819,769	458,610	90,792	636,792
19	2,666	23,407	488,500	478,236	229,569	707,642
20	2,911	18,095	610,953	444,352	360,217	391,199
21	2,629	715,799	37,363	281,372	208,229	236,185

Parameter hasil *clustering* dari *slice sagittal* ditunjukkan oleh Tabel 4.7, Tabel 4.8, dan Tabel 4.9. *Slice sagittal* memiliki 21 *slice* citra MRI yang dikelompokkan menjadi 6 klaster. Pada Tabel 4.9 terlihat bahwa varians dari klaster satu selalu lebih kecil daripada klaster yang lain. Keragaman dari klaster 1 yang kecil disebabkan oleh anggota klaster 1 banyak yang memiliki intensitas keabuan yang gelap (mendekati 0) dan membentuk puncak histogram yang tinggi namun sempit.




**Gambar 4.12** Histogram 6 Klaster Citra *Slice Sagittal* ke-16

Gambar 4.12 menunjukkan histogram *mixture model* yang membentuk 6 klaster untuk *slice sagittal* ke-16. Jika parameter dalam Tabel 4.7, Tabel 4.8, dan Tabel 4.9 dibentuk menjadi model GMM maka model umumnya adalah sebagai berikut.

$$\begin{aligned}
 & f(x | \mu_j, \sigma_j^2, \pi_j) \\
 &= \sum_{j=1}^6 \pi_j N(x | \mu_j, \sigma_j^2) \\
 &= \pi_1 N(x | \mu_1, \sigma_1^2) + \pi_2 N(x | \mu_2, \sigma_2^2) + \pi_3 N(x | \mu_3, \sigma_3^2) + \pi_4 N(x | \mu_4, \sigma_4^2) + \pi_5 N(x | \mu_5, \sigma_5^2) + \pi_6 N(x | \mu_6, \sigma_6^2) \\
 &= 0.251 N(x | 2.511, 3.206) + 0.284 N(x | 66.301, 22.866) + 0.363 N(x | 55.665, 674.789) \\
 &\quad + 0.066 N(x | 122.43, 436.616) + 0.024 N(x | 162.729, 281.802) + 0.010 N(x | 212.967, 317.766)
 \end{aligned}$$






**Gambar 4.13** Hasil Citra *Slice Sagittal* ke-10 (a) Gambar Asli (b) Hasil *Clustering*

Gambar 4.13 (a) adalah gambar asli hasil citra MRI dari *sagittal slice* ke-16 sedangkan Gambar 4.13 (b) adalah hasil citra MRI yang telah melakukan proses *clustering* sehingga terbagi menjadi 6 klaster. Area tumor yang masuk menjadi anggota klaster 4 ternyata memiliki kesamaan *grayscale* dengan area tepi atau bagian tulang. Namun terlihat bahwa area tumor berbeda klaster dengan area otak.

**NROI-Non region of interest**




**ROI-region of interest**



**Gambar 4.14** NROI dan ROI dari Citra *Slice Sagittal* ke-16

Gambar 4.14 menunjukkan bagian NROI dan ROI dari *slice sagittal* ke-16. Klaster 4 dipilih menjadi ROI karena area tumor masuk dalam klaster 4. Anggota klaster lainnya menjadi Non-ROI atau *non region of interest*.



**Gambar 4.15** Perbandingan Nilai *Silhouette Index* Klaster 5 hingga 8  
*Slice Sagittal*

Nilai *Silhouette Index* yang dihasilkan dari *clustering* untuk *slice sagittal* ditunjukkan pada Gambar 4.15. Pada gambar terlihat bahwa 5 klaster memiliki nilai SI yang cukup tinggi namun juga cukup rendah pada beberapa *sequence*. Nilai SI yang cukup rendah tersebut berada pada *sequence* dimana terdapat bentuk yang jelas dari bagian tumor otak. Pada 6 klaster, *sequence* yang memiliki gambar tumor otak yang jelas memiliki nilai SI yang cukup baik. Selain itu 6 klaster juga dapat memisahkan area ROI dan NROI lebih baik dibandingkan dengan klasifikasi 5 klaster, sehingga dipilih 6 klaster untuk mengklasifikasikan *grey-scale* dari hasil citra MRI *slice sagittal*.


### 4.3 Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI


Setelah dilakukan *clustering* pada hasil citra MRI langkah selanjutnya adalah memodelkan dalam bentuk 3 dimensi. Hal ini dilakukan untuk mengetahui letak tumor berdasarkan ROI. Pemodelan 3 dimensi dilakukan tiap *sequence* (*axial*, *coronal*, dan *sagittal*). Penentuan daerah tumor selain berdasarkan hasil ROI namun juga menggunakan *toolbox* dari *Matlab* sehingga daerah ROI yang bukan merupakan bagian dari tumor seperti tengkorak atau garis-garis otak yang lain dapat diabaikan. Pengolahan hasil citra didasarkan pada subjektivitas visual agar tampilan visual bisa lebih jelas.

#### 4.3.1 Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI

##### *Slice Axial*

Pemodelan 3 dimensi dari *slice axial* menampilkan hasil citra MRI *slice axial* yang disusun ke bawah sesuai urutan gambar sehingga membentuk sebagian kepala dari pasien. Daerah ROI didapatkan dari hasil *clustering* pada *slice* ke-19 di mana bentuk tumor paling jelas terlihat sehingga dapat digunakan untuk mewakili bentuk tumor. ROI pada *slice* ke-19 diambil hanya daerah tumor saja agar dapat digunakan untuk membentuk tumor dalam model otak 3 dimensi.






**Gambar 4.16** Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI  
*Slice Axial*

Gambar 4.16 adalah model 3 dimensi dari *slice axial* yang dilihat dari beberapa sisi. Bentuk kepala yang terbentuk memang tidak berbentuk secara lengkap namun hanya sebagian dan tidak sampai dagu. Hal ini dikarenakan *file* hasil citra MRI fokus pada bagian otak sehingga tidak terdapat *slice* lengkap dari kepala.

Selanjutnya untuk memperlihatkan tumor otak yang berada di dalam otak, dilakukan penyesuaian *opacity* dari bagian


kepala. Penyesuaian ini dilakukan pada bagian *Image Intensity* yang terletak pada sebelah kanan. Bagian tumor diatur agar terlihat paling jelas sementara bagian kepala yang lain diatur agar terlihat transparan dan bagian otak diatur agar terlihat samar. Hasilnya terlihat pada Gambar 4.17.



**Gambar 4.17** Letak Tumor dalam Model 3 Dimensi Hasil *Clustering* Hasil Citra MRI *Slice Axial*


#### 4.3.2 Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI *Slice Coronal*

*Slice coronal* merupakan penggambaran kepala dari arah depan ke belakang. Setiap hasil citra MRI *slice coronal* disusun ke belakang sesuai urutan. Hasil *clustering* dari *slice* ke-10 digunakan untuk memperkirakan bentuk tumor otak karena terdapat ROI yang jelas menggambarkan tumor. Pada *slice* ke-10 terdapat bagian tengkorak yang ikut menjadi ROI namun diolah kembali agar pemodelan fokus pada bagian tumor.



**Gambar 4.18** Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI  
*Slice Coronal*


Model 3 dimensi dari *slice coronal* ditunjukkan oleh Gambar 4.18. Model dari *slice coronal* hanya menampilkan sebagian dari kepala pasien, tidak sampai ke bagian wajah. Hasil *clustering* tampak pada perbedaan warna dari model. Pada Gambar 4.18 tidak terlihat tumor otaknya karena tumor berada di dalam bagian otak. Berikut ini Gambar 4.19 yang menunjukkan letak tumor pada *slice coronal*.



**Gambar 4.19** Letak Tumor dalam Model 3 Dimensi Hasil *Clustering* Hasil Citra MRI *Slice Coronal*

#### 4.3.3 Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI *Slice Sagittal*


Model 3 dimensi dari *slice sagittal* menampilkan hasil citra MRI yang disusun ke samping sesuai urutan gambar sehingga membentuk sebagian kepala dari pasien. Daerah ROI yang digunakan untuk membentuk bagian tumor berasal *clustering* pada *slice* ke-16. *Slice* ke-16 merupakan ROI dengan bentuk tumor paling jelas terlihat sehingga dapat digunakan untuk mewakili bentuk tumor.



**Gambar 4.20** Pemodelan 3 Dimensi Hasil *Clustering* Hasil Citra MRI  
*Slice Sagittal*



Gambar 4.20 adalah model 3 dimensi dari *slice sagittal*. Penampang kepala yang terbentuk tidak membentuk kepala secara lengkap namun hanya sebagian saja. *Slice sagittal* terdiri dari 22 potongan gambar dari sisi menyamping.



**Gambar 4.21** Letak Tumor dalam Model 3 Dimensi Hasil *Clustering* Hasil Citra MRI *Slice Sagittal*

Tumor otak yang berada di dalam akan terlihat setelah dilakukan penyesuaian *opacity* sehingga bagian kepala yang lain dapat dibuat transparan dan tersisa bagian otak dan tumornya. Berdasarkan hasil pemodelan 3 dimensi dari *slice axial*, *coronal*, dan *sagittal* diketahui bahwa tumor berada pada bagian kiri kepala pasien. Penyusunan gambar disesuaikan dengan urutan *file* hasil citra MRI.

*(Halaman ini sengaja dikosongkan)*

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Hasil segmentasi citra MRI tumor otak menggunakan *Gaussian Mixture Model* dengan pendekatan *Expectation Maximization* adalah sebagai berikut.

1. Ketiga bagian dari hasil citra MRI yang terdiri dari *axial*, *coronal*, dan *sagittal* memiliki kesamaan bentuk histogram citra yaitu sama-sama memiliki puncak yang tinggi pada intensitas keabuan mendekati nol atau warna paling gelap. Terlihat beberapa puncak yang terbentuk namun belum tentu sesuai dengan penentuan kluster. Jumlah kluster yang ditentukan adalah 6 kluster. Penentuan ini didasarkan pada analisis subjektif peneliti agar objek dapat ditangkap dengan jelas. Jumlah kluster disamakan untuk semua bagian agar memudahkan saat proses pembentukan model 3 dimensi. Area tumor dari hasil citra MRI yang dijadikan *region of interest* (ROI) terdapat pada kluster ke-4.
2. Pemodelan 3 dimensi dilakukan di masing-masing *slice* yaitu *slice axial*, *coronal*, dan *sagittal*. *Slice* yang dijadikan acuan pembentukan bagian tumor otak adalah *slice* yang memiliki ROI tumor paling jelas. Hasil *clustering* diolah kembali agar ROI selain bagian tumor dapat diabaikan.

#### **5.2 Saran**

Pengolahan hasil citra MRI perlu dilakukan lebih lanjut agar dapat mempermudah pekerjaan paramedik dalam penentuan diharapkan menggunakan metode *unknown-number component of mixture* agar citra yang dihasilkan semakin jelas. Kriteria ke-baikannya perlu juga ditambahkan agar proses *clustering* lebih optimal.

*(Halaman ini sengaja dikosongkan)*

## DAFTAR PUSTAKA

- Ahmad, U. (2005). *Pengolahan Citra Digital & Teknik Pemrogramannya*. Yogyakarta: Graha Ilmu.
- American Brain Tumor Association. (2015). *About Brain Tumors A Primer for Patients and Caregivers*. Chicago: ABTA.
- Aristophanous, M., Penney, B. C., Martel, M. K., & Pelizzari, C. A. (2007). A Gaussian Mixture Model for Definition of Lung Tumor Volumes in Positron Emission Tomography. *Medical Physics*, 4224.
- Ayub. (2015). *Tumor Otak*. Diakses dari Docslide: <https://dokumen.tips/documents/tumor-otak-dr-ayubspdoc.html>
- Box, G. E., & Tiao, G. C. (1973). *Bayesian Inference in Statistical Analysis* (1st ed.). Reading: Addison Wesley Publishing Company.
- Carlin, B. P., & Chib, S. (1995). Bayesian Model Choice via Markov Chain Monte Carlo Methods. *Journal of the Royal Statistical Society*, 57(3), 473-484.
- Casella, G., & George, E. I. (1992). Explaining the Gibbs Sampler. *The American Statistician*, 46, 167-174.
- Cook, L. J., & Freedman, J. (2012). *Brain Tumors, Understanding Brain Diseases and Disorders*. New York: The Rosen Publishing Group.
- Dempster, A. P., Laird, N. M., dan Rubin, D. B. (1977). *Maximum Likelihood from Incomplete Data via EM Algorithm*. *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 39. 1.
- Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A., & Rubin, D. B. (2014). *Bayesian Data Analysis (3 ed.)*. Boca Raton: CRC Press.
- Gonzales, R. C., & Woods, R. E. (2008). *Digital Image Processing* (3rd ed.). New Jersey: Pearson Prentice Hall.
- Iriawan, N. (2001). *Penaksiran Model Mixture Normal Univariabel: Suatu pendekatan Metode Bayesian dengan MCMC*.

- Seminar Nasional dan Konferda VII Matematika Wilayah DIY dan Jawa Tengah*. Yogyakarta.
- Ji, Z., Huang, Y., Sun, Q., Cao, G., & Zheng, Y. (2017). A Rough Set Bounded Spatially Contstrained Asymmetric Gaussian Mixture Model for Image Segmentation. *PLoS ONE*.
- Kumar, N. S., Satoor, S., & Buck, I. (2009). Fast Parallel Expectation Maximization for Gaussian Mixture Models on GPUs using CUDA. *2009 11th IEEE International Conference on High Performance Computing and Communications*, 103-105.
- Krishnan, P. H. dan DR. Ramamoorthy, P. (2014). *Fuzzy Clustering based Ant Colony Optimization Algorithm for MR Brain Image Segmentation*. Research Scholar, Department of Electrical Engineering, SNS College of Technology, Coimbatore.
- Kumbara, B. (2015). *Klasifikasi dan Ekstraksi Sinyal EEG-P300 Menggunakan Support Vector Machine untuk Deteksi Kebohongan*. Bandung: Universitas Pendidikan Indonesia.
- Laader, A., Beiderwellen, K., Kraff, O., Maderwald, S., Wrede, K., Ladd, M. E., et al. (2017). 1.5 versus 3 versus 7 Tesla in Abdominal MRI: A Comparative Study.
- McLachlan, G., & Peel, D. (2000). *Finite Mixture Model*. New York: John Wiley & Sons, Inc.
- Munir, R. (2006). Aplikasi Image Thresholding Untuk Segmentasi Objek. *Seminar Nasional Aplikasi Teknologi Informasi 2006* (pp. F-1 - F-6). Yogyakarta: SNATI.
- Munir, R. (2004). *Pengolahan Citra Digital*. Bandung: Informatika.
- Neuroradiology Learning Module: University of Wisconsin School of Medicine and Public Health*. Diakses dari <https://sites.google.com/a/wisc.edu/neuroradiology/image-acquisition/the-basics>
- Nguyen, T. M. (2011). *Gaussian Mixture Model based Spatial Information Concept for Image Segmentation*. Ontario: University of Windsor.

- Noyosiswoyo, M., & Suswati, S. (2004). Pemanfaatan Magnetic Resonance Imaging (MRI) sebagai Saranan Diagnosa Pasien. *Media Litbang Kesehatan Volume XIV Nomor 3 Tahun 2004*, 8-13.
- Pasien BPJS (2016). Diakses dari Pasien BPJS: <http://www.pasienbpjs.com/2016/11/mri-rongtsen-ct-scan-ditanggung-bpjs.html>
- Rofiky, A., Rahardjo, P., & Soeharmanto, D. (2017). Comparison of Number of Difussion Gradient Direction in Brain Imaging Diffusion Tensor; Case Study of Tumor Brain. 15-17.
- RS Premier Surabaya (2017). Diakses dari RS Premier Surabaya: [rs-premiersurabaya.com/deteksi-lebih-akurat-menggunakan-mri-3-tesla](http://rs-premiersurabaya.com/deteksi-lebih-akurat-menggunakan-mri-3-tesla)
- Shapiro, L., & Stockman, G. (2000). *Computer Vision*. New Jersey: Prentice Hall.
- Sianipar, W. H. (2017). *Komparasi metode EM-GMM (Expectation Maximization-Gaussian Mixture Model) dan FCM (Fuzzy C-Means) dalam Segmentasi Citra Otak MRI (Magnetic Resonance Imaging) di RSUD Soetomo dalam Menentukan Area Tumor Otak*. Surabaya: Institut Teknolgi Sepuluh Nopember.
- Tan, P.-N., Steinbach, M., & Kumar, V. (2005). *Introduction to Data Mining*. Boston: Pearson Addison Wesley.
- Wahjoepramono, E. J. (2006). *Tumor Otak*. Tangerang: Fakultas Kedokteran Universitas Pelita Harapan.
- Wijaya, R. (2017). *Mengenal Tumor Otak dan Pemulihan Canggihnya di Indonesia*. Diakses dari Lawan Kanker: <https://lawankanker.org/teknologi-canggih-pemulihan-tumor-otak-di-indonesia/>
- Xiaong, T.-S., & Huang, Y.-Y. (2015). Robust Gaussian Mixture Modelling Based on Spatially Constraints for Image Segmentation. *Journal of Information Hiding and Multimedia Signal Processing*, 6(5), 857-868.

*(Halaman ini sengaja dikosongkan)*



## LAMPIRAN

### **Lampiran 1** *Syntax Clustering dengan Gaussian Mixture Model dengan Pendekatan Expectation Maximization*

```
function [mask,mu,v,p]=seg6(ima,k)
%%
%check image
ima=double(ima);
ima=imresize(ima,[512 512]);
copy=ima;
copy2=ima;% make a copy
ima=ima(:);           % vectorize ima
mi=min(ima);          % deal with negative
ima=ima-mi+1;          % and zero values
m=max(ima);
s=length(ima);
%%
% histogram citra
h=histogram(ima);
x=find(h);
h=h(x);
x=x(:);h=h(:);
%%
% insiasi parameter

mu=(1:k)*m/(k+1);
v=ones(1,k)*m;
p=ones(1,k)*1/k;

% mulai proses

sml = mean(diff(x))/1000;
while(1)
    % Expectation
    prb = distribution(mu,v,p,x);
    scal = sum(prb,2)+eps;
    loglik=sum(h.*log(scal));
```

**Lampiran 1** *Syntax Clustering dengan Gaussian Mixture Model*  
dengan Pendekatan *Expectation Maximization*  
(Lanjutan)

```

%Maximization
for j=1:k
    pp=h.*prb(:,j)./scal;
    p(j) = sum(pp);
    mu(j) = sum(x.*pp)/p(j);
    vr = (x-mu(j));

    v(j)=sum(vr.*vr.*pp)/p(j)+sml; %update
    variance
end
p = p + 1e-3;
p = p/sum(p);

% Exit condition
prb = distribution(mu,v,p,x);
scal = sum(prb,2)+eps;
    nloglik=sum(h.*log(scal));
    if((nloglik-loglik)<0.0001)
        break;
    end;
clf
%plot(x,h);
hold on
plot(x,prb,'g--')
%plot(x,sum(prb,2),'r')
drawnow
end
v
save nloglik
%%
% menghitung mask
mu=mu+mi-1;
s=size(copy);
mask=zeros(s);

```

**Lampiran 1** *Syntax Clustering dengan Gaussian Mixture Model  
dengan Pendekatan Expectation Maximization*

```

for i=1:s(1),
for j=1:s(2),
    for n=1:k

        c(n)=distribution(mu(n),v(n),p(n),copy
            (i,j));

    end
    a=find(c==max(c));
    mask(i,j)=a(1);
end
end
figure,imshow(mask/255,[]);

%%
%subjective analysis
orgimg=copy;
[r,c]=find(mask==4);
rc=[r,c];
for j=1:(numel(rc)/2)
    copy(r(j),c(j))=0;
end
figure, subplot(1,2,1);
imshow(copy,[]), title('NROI-Non region of in-
    terest');
nroi_image=copy;
logimg=imsubtract(orgimg,copy);
roi_image=logimg;
subplot(1,2,2);
imshow(logimg,[]), title('ROI-region of inter-
    est');

%%
[h,v]=size(mask==4);
tumour_area=(1/h)*(1/v)*(sum(sum(mask==4)));
display('area of tumour is :');
display (tumour_area);
D.tumour_area=tumour_area;
save tumour_area

```

**Lampiran 1** *Syntax Clustering dengan Gaussian Mixture Model dengan Pendekatan Expectation Maximization (Lanjutan)*

```
%%
%pixel calculation
[h,v]=size(mask==4);
number_pixel=(sum(sum(mask==4)));
display('number of pixel in the tumor area :');
display (number_pixel);
D.number_pixel=number_pixel;
save number_pixel
%%
varr1 = edge(logimg,'canny');
varr2 = imfuse(copy2,varr1);
fuse_image=varr2;
figure,imshow(varr2), title('subjective analysis');

%%
function y=distribution(m,v,g,x)
%%
x=x(:);
m=m(:);
v=v(:);
g=g(:);
for i=1:size(m,1)
    d = x-m(i);
    amp = g(i)/sqrt(2*pi*v(i));
    y(:,i) = amp*exp(-0.5 * (d.*d)/v(i));
end
%%
function[h]=histogram(datos)
%%
datos=datos(:);
ind=find(isnan(datos)==1);
datos(ind)=0;
ind=find(isinf(datos)==1);
datos(ind)=0;
tam=length(datos);
```

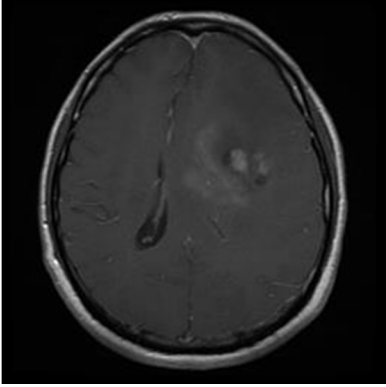
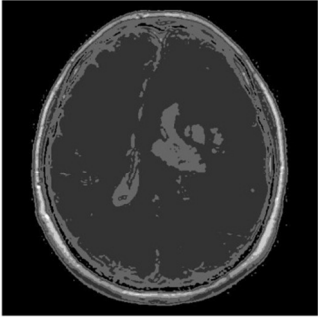
**Lampiran 1** *Syntax Clustering dengan Gaussian Mixture Model dengan Pendekatan Expectation Maximization (Lanjutan)*

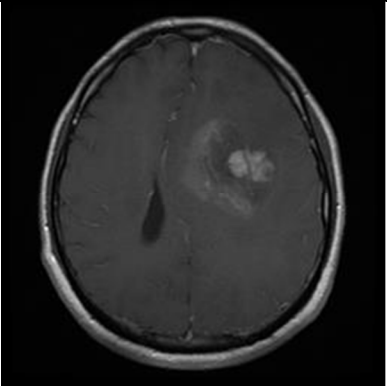
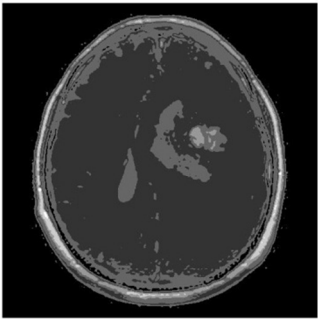
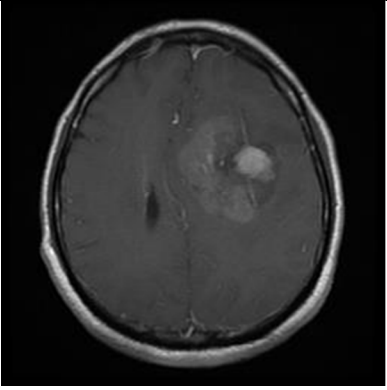
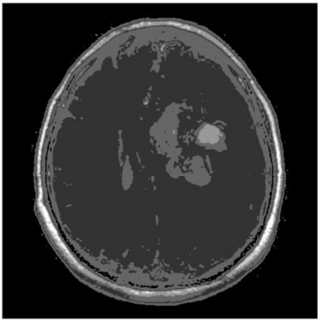
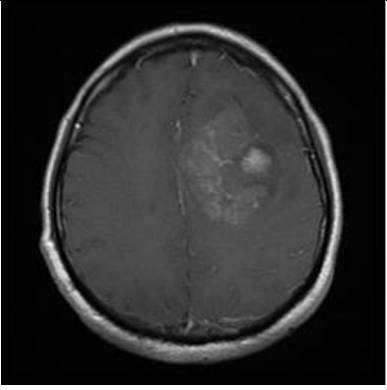
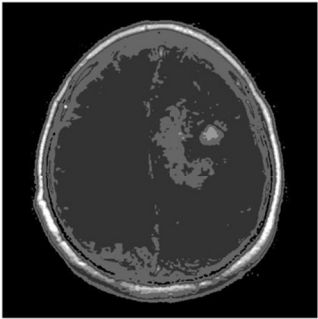
```

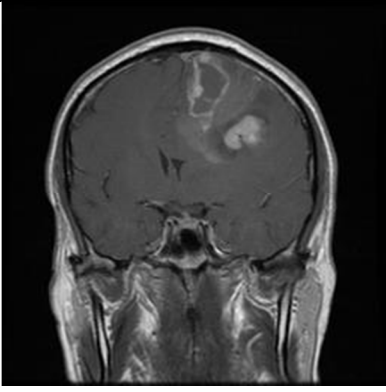
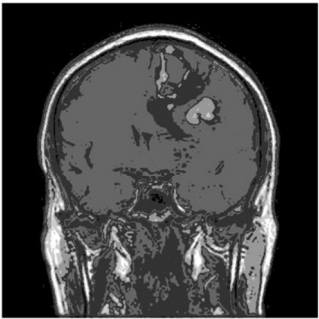
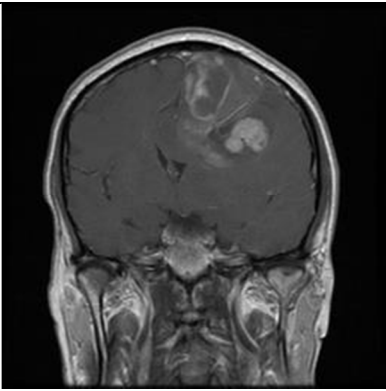
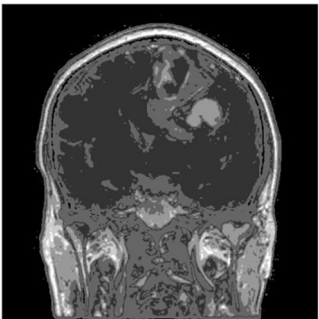
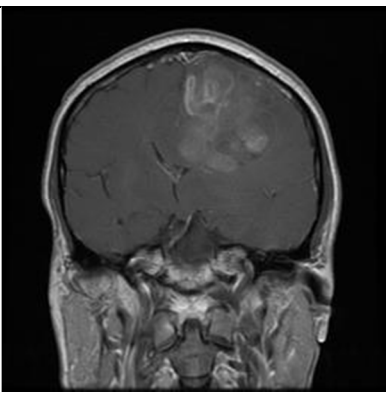
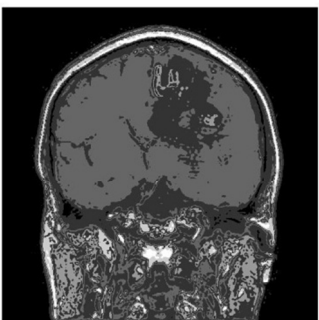
h=zeros(1,m);
for i=1:tam,
    f=floor(datos(i));
    if(f>0 & f<(m-1))
        a2=datos(i)-f;
        a1=1-a2;
        h(f) =h(f) + a1;
        h(f+1)=h(f+1)+ a2;
    end;
end;
h=conv(h,[1,2,3,2,1]);
h=h(3:(length(h)-2));
h=h/sum(h);

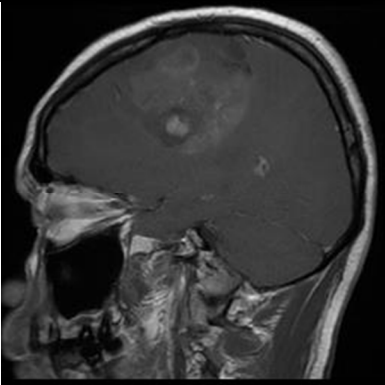
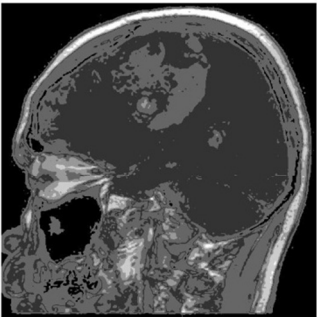
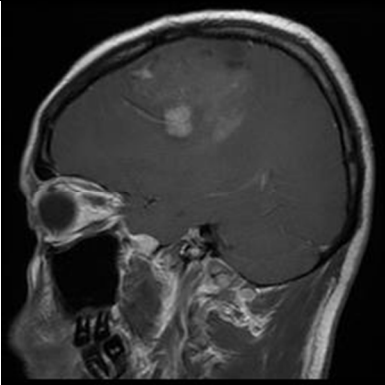
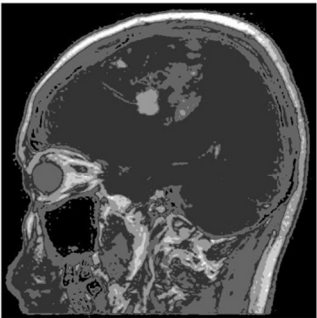
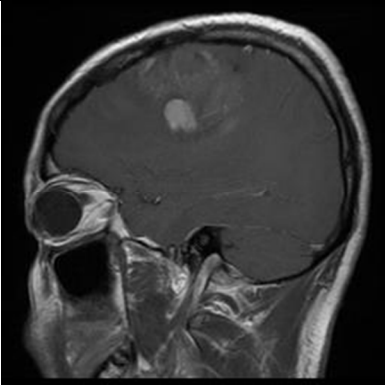
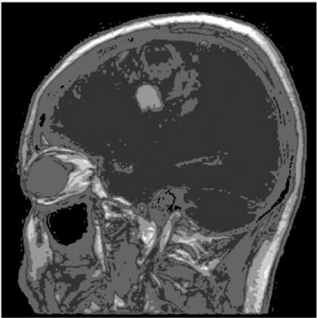
```

**Lampiran 2** Hasil *Clustering* Beberapa *Slice* dari Citra MRI yang Terdapat Area Tumor Otak yang Tampak

<i>Slice Ke-</i>	Hasil Citra MRI	Hasil <i>Clustering</i>
17		

18		
19		
20		

9		
10		
11		

15		
16		
17		



**Lampiran 3** *Syntax Mendapatkan Nilai Silhouette Index*

```
SI=silhouette(data,idx);  
SI_cluster=[mean(SI(idx==1)) mean(SI(idx==2))  
mean(SI(idx==3))  
mean(SI(idx==4)) mean(SI(idx==5))  
mean(SI(idx==6)) mean(SI(idx==7))  
mean(SI(idx==8)) ]  
SI_all=mean(SI_cluster)
```

## Lampiran 4 Surat Pernyataan Data Sekunder

### SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Program Sarjana Departemen Statistika FMKSD ITS.

Nama : Siti Azizah Nurul Solichah

NRP : 062116 4500 0008

menyatakan bahwa data yang digunakan dalam Tugas Akhir ini, merupakan data sekunder bagian dari penelitian Disertasi mahasiswa Program Doktor Departemen Statistika FMKSD ITS yaitu:

Judul : *Spatially Constrained Neo-Normal Mixture Model* dengan Pendekatan Bayesian Pada Segmentasi Citra MRI Tumor Otak

Oleh : Anindya Apriliyanti Pravitasari

NRP : 1315301003

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka mahasiswa bersedia menerima sanksi sesuai aturan yang berlaku.

Mengetahui,  
Pembimbing Tugas Akhir



Prof. Drs. Nur Iriawan, Mkom., Ph.D.  
NIP. 19621015 198803 1 002

Surabaya, 30 Juli 2018



Siti Azizah Nurul Solichah  
NRP. 062116 4500 0008

## BIODATA PENULIS



Penulis memiliki nama lengkap SITI AZIZAH NURUL SOLICHAH yang sering dipanggil Siti, Azizah, atau Ijah. Lahir di Surabaya tanggal 21 Agustus 1996 dengan predikat anak tunggal. Bertempat tinggal di Jl. Ketintang Baru XVII 54 D Surabaya. Penulis telah menempuh pendidikan formal hingga Sekolah Menengah Atas di Surabaya. Mulai dari TK Kemala Bhayangkari I Surabaya, SD Kemala Bhayangkari I Surabaya, SMP Negeri 1 Surabaya, dan SMA Negeri 5 Surabaya. Lulus dari SMA, penulis melanjutkan pendidikannya di Diploma III Statistka ITS dan selanjutnya jenjang Sarjana melalui Lintas Jalur S1 Statistika ITS. Selama perkuliahan penulis aktif mengikuti kegiatan kepanitiaan dan organisasi di lingkup Kampus ITS. Bagian dari fungsionaris HIMADATA-ITS untuk kepengurusan tahun pertama dan kedua sebagai staf Departemen Hubungan Luar HIMADATA-ITS 2014/2015 dan Sekretaris Departemen Hubungan Luar HIMADATA-ITS 2015/2016. Saat menjalani perkuliahan, aktif dalam Unit Kegiatan Mahasiswa (UKM) Futsal Putri ITS pada tahun pertama dan menjadi bagian dari Tim Futsal Putri HIMADATA-ITS. Memiliki pengalaman kerja praktik di PT. ARUKI dan PT. Campina *Ice Cream Industry*. Kritik, saran, dan masukan dapat dikirim melalui email penulis [sitiazizah.ns@gmail.com](mailto:sitiazizah.ns@gmail.com).